



João Quintas

Deteccção Automática de Crepitações em Sons Respiratórios

João Quintas



Universidade de Aveiro Departamento de Electrónica, Telecomunicações e
2010/2011 Informática

Deteccção Automática de Crepitações em Sons Respiratórios

Dissertação apresentada à Universidade de Aveiro para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Engenharia Electrónica e Telecomunicações (M.I.E.E.T.), realizada sob a orientação científica dos Professores Auxiliares da Universidade de Aveiro Guilherme Campos (Departamento de Electrónica, Telecomunicações e Informática) e Alda Marques (Escola Superior de Saúde).

The world is never quiet, even its silence eternally resounds
with the same notes, in vibrations which escape our ears. As
for those that we perceive, they carry sounds to us,
occasionally a chord, never a melody.
Albert Camus

o júri

presidente

Doutor João Paulo Trigueiros da Silva Cunha

Professor Associado com Agregação do Departamento de Electrónica, Telecomunicações e Informática da Universidade de Aveiro

vogais

Doutor Jorge Manuel Oliveira Henriques

Professor Auxiliar do Departamento de Engenharia Informática da Faculdade de Ciências e Tecnologia da Universidade de Coimbra

Doutor António Guilherme Campos

Professor Auxiliar do Departamento de Electrónica, Telecomunicações e Informática da Universidade de Aveiro

Doutora Alda Sofia Pires de Dias Marques

Professora Auxiliar da Escola Superior de Saúde da Universidade de Aveiro

Agradecimentos / Acknowledgements

Antes de mais agradeço aos meus pais, por todo o apoio, esforço, carinho e amor ao longo de toda a minha vida. Sem eles isto não teria passado de uma mera utopia.

Um agradecimento especial ao Prof. Guilherme Campos, por todo o apoio e companheirismo, demonstrando sempre uma disponibilidade excepcional para discutir qualquer assunto e oferecendo-me óptimas condições para o desenvolvimento do meu trabalho.

Um agradecimento à Prof. Alda Marques pela vontade que sempre demonstrou em ajudar-me.

Um agradecimento ao João Dinis e à Cátia Pinho, pela companhia, pelas ideias e pelas conversas sempre proveitosas para o desenvolvimento do projecto.

Um agradecimento novamente à Prof. Alda Marques mas também à Daniela Oliveira e à Doutora Ilka Martins por terem disponibilizado o seu precioso tempo para fazer as anotações.

Um agradecimento à Ana, pelo apoio nos bons, mas principalmente nos maus momentos. Pela paciência, pelo carinho e por estar sempre ao meu lado quando mais preciso.

Um agradecimento ao Leonardo por nunca me ter fechado a porta sempre que precisei.

Um agradecimento a todos os meus amigos, quer de Aveiro, quer de Braga, pelos bons momentos, pelas histórias, pelas vivências, por moldarem aquilo que sou hoje.

Palavras-chave

sons respiratórios, sons pulmonares adventícios, crepitações, anotações, algoritmos de detecção, Savitzky-Golay, *fractal dimension*, *wavelet transform*, acordo, sensibilidade, precisão, média harmónica

Resumo

Esta dissertação explora métodos automáticos de detecção de crepitações. É descrita e discutida a implementação em *MatLab* de quatro algoritmos propostos na literatura. O primeiro é o de Vannuccini et al. [1], que envolve a aplicação de filtros *Savitzky Golay* – SG. O segundo é o de Hadjileontiadis e Rekanos [2], baseado no cálculo da *Fractal Dimension* – FD. O terceiro é uma versão alternativa do anterior substituindo o algoritmo de Katz pelo de Sevcik [3] para o cálculo da FD. O último é o proposto por Bahoura e Lu, baseado em *Wavelet packet-based stationary and non stationary filters* - WPST_NST [4] (com algumas adaptações).

A avaliação de desempenho foi realizada sobre um repositório composto por 10 sons respiratórios (5 de pacientes com fibrose quística e 5 de pacientes com pneumonia) devidamente anotados por 3 profissionais de saúde. Por acordo entre as suas anotações, geraram-se referências para o cálculo dos valores de sensibilidade (SE), de precisão (PPV) e da média harmónica destes para os vários algoritmos.

Para efeitos de teste, definiram-se empiricamente gamas úteis de detecção para cada algoritmo e grelhas de 10 limiares uniformemente espaçados nessas gamas úteis. Nos limiares de máximo desempenho (considerando resultados médios no repositório) obtiveram-se SE=87,5% e PPV=71,6% (F=77,4%) para o primeiro algoritmo, SE=91,4% e PPV=74,5% (F=81%) para o segundo, SE=91,5% e PPV=72,14% (F=79,4%) para o terceiro e SE=89,6% e PPV=71,9% (F=78,7%) para o último.

Por combinação de filtros SG e do algoritmo FD de Sevcik estabeleceu-se um novo algoritmo híbrido (SG-FD) cujo máximo desempenho (considerando resultados médios no repositório) foi SE=84,75% e PPV=62,57% (F=65%).

Finalmente, explorou-se a detecção por acordo entre algoritmos. Obtiveram-se anotações de acordo para cada um dos 10 ficheiros do repositório considerando todas as 10000 combinações de limiares possíveis. No ponto de desempenho óptimo (considerando resultados médios no repositório) obtiveram-se SE=91,4% e PPV=83,7%. A média harmónica (F) atinge 86,7%, superando em 7% o máximo obtido com algoritmos individuais (F=81% para o algoritmo de Hadjileontiadis e Rekanos).

Keywords

respiratory sounds, adventitious lung sounds, crackles, pulmonary diseases, gold standards, Savitzky-Golay, *fractal dimension*, *wavelet transform*, agreement, sensitivity, precision, harmonic mean

Abstract

This dissertation explores automatic methods for crackle detection. It describes and discusses the *MatLab* implementation of four algorithms proposed in the literature. The first, by Vannuccini et al. [1], involves the application of Savitzky Golay (SG) filters. The second, by Hadjileontiadis and Rekanos [2], is based on the Fractal Dimension (FD) function. The third is an alternative version of the previous one, replacing the Katz algorithm by the Sevcik [3] algorithm for calculating the waveform's FD. The last one proposed, by Bahoura and Lu, is based on Wavelet packet-based stationary and non stationary filters – WPST-NST [4] (implemented with a few adaptations).

Performance evaluation was based on a repository of 10 respiratory sounds (5 from patients with cystic fibrosis and 5 from patients with pneumonia) duly annotated by three health professionals. By agreement among their annotations, references were generated to calculate the values of sensitivity (SE), accuracy (PPV) and their harmonic mean (F) of the various algorithms.

The useful threshold ranges of the four algorithms were empirically established and a set of 10 evenly spaced thresholds were defined for each. The top performance thresholds (considering average results in the repository) yielded SE=87.5% and PPV=71.6% (F=77.4%) for the first algorithm, SE=91.4% and PPV=74.5% (F=81%) for the second, SE=91.5% and PPV=72.14% (F=79.4%) for the third and SE=89.6% and PPV=71.9% (F=78.7%) for the fourth.

By combining SG filters and Sevcik's FD algorithm, a new hybrid algorithm (SG-FD) was established, whose maximum performance (considering average results in the repository) was SE=84,75% and PPV=62,57% (F=65%).

Finally, detection by agreement between algorithms was explored. Agreement annotations were obtained for each of the 10 files in the repository considering every one of the 10,000 possible combination thresholds.

At the point of optimal performance (average results in the repository) SE=91,4% and PPV=83,7% were obtained. The harmonic mean (F) reached 86.7%, surpassing by 7% the top performance achieved with individual algorithms (F=81% for the Hadjileontiadis and Rekanos algorithm).

Índice

1. Introdução	1
1.1. Motivação e Contexto	1
1.2. Objectivos	2
1.3. Estrutura da dissertação	2
2. Sons Respiratórios	5
2.1. Sistema Respiratório.....	5
2.2. Classificação das Patologias Respiratórias	6
2.3. Diagnóstico e Monitorização.....	6
2.4. Classificação de Sons Respiratórios	8
2.4.1. Sons Normais	9
2.4.1.1 Sons Traqueais	9
2.4.1.2 Sons Pulmonares.....	9
2.4.2. Sons Pulmonares Adventícios (SPA).....	9
2.4.2.1 Crepitações.....	10
2.4.2.2 Sibilâncias.....	11
3. Anotação de Sons Respiratórios	13
3.1. Avaliação de Desempenho (Validação)	13
3.2. Anotações de Referência.....	14
3.2.1. Anotação de Crepitações	15
3.2.2. Acordo entre Anotadores.....	15
3.3. Repositório de Estudo	19
4. Detecção e Classificação de Crepitações	21
4.1. Caracterização.....	21
4.2. Detecção automática	24
4.2.1. Estrutura Geral dos Algoritmos	24
4.2.2. Evolução Histórica	25
4.3. Algoritmo de Vannuccini et al.	28
4.3.1. Esquema Global	28
4.3.2. Parâmetros de Entrada	29
4.3.3. Filtragem Savitzky-Golay.....	29
4.3.4. Localização das Zonas de Interesse.....	30
4.3.5. Detecção de Crepitações.....	31
4.3.6. Validação do Algoritmo	32
4.4. Algoritmo de Hadjileontiadis e Rekanos	32
4.4.1. Esquema Global	32
4.4.2. Cálculo da FD	33
4.4.3. Identificação Automática dos Picos na FD.....	35
4.4.4. Validação	36
4.5. Algoritmo de Bahoura e Lu	37
4.5.1. Esquema Global	37

4.5.2.	Parâmetros de Entrada	37
4.5.3.	Filtro WPST-NST	38
4.5.4.	Filtro de remoção de ruído	40
4.5.5.	Detecção de Crepitações. Algoritmo FD	41
4.5.6.	Detecção dos Picos das Crepitações (CPD)	41
4.5.7.	Classificação das Crepitações	43
4.5.8.	Validação do Algoritmo	43
5.	Implementação e Avaliação de Detectores de Crepitações	45
5.1.	Algoritmo de Vannuccini et al.	45
5.1.1.	Versão Original	45
5.1.2.	Variante	50
5.2.	Algoritmo <i>Fractal Dimension</i> (FD)	54
5.2.1.	Método de Hadjileontiadis e Rekanos	54
5.2.2.	Versão de Sevcik	58
5.3.	Algoritmo de Bahoura e Lu	62
6.	Desenvolvimento de Métodos Híbridos	65
6.1.	Híbrido SG-FD	65
6.2.	Acordo entre Algoritmos	67
6.2.1.	Procedimento	67
6.2.2.	Resultados	68
7.	Conclusões e Trabalho Futuro	73
7.1.	Conclusões	73
7.2.	Trabalho Futuro	74
Anexo A – Interface Gráfica		77
A.1	Conteúdos	77
A.2	Apresentação	77
A.3	Procedimento	79
Anexo B – Algoritmo de Acordo		85
Anexo C – Algoritmo de Vannuccini et al.		87
Anexo D – Algoritmo de Hadjileontiadis e Rekanos		89
Anexo E – Algoritmo FD de Sevcik		91
Anexo F – Algoritmo de Bahoura e Lu		93
Anexo G – Algoritmo SG-FD		95
Anexo H – Acordo entre Algoritmos		97
Referências		99

Índice de Figuras

Figura 2.1 – Sistema Respiratório	6
Figura 2.2 – Nomenclatura geral dos sons respiratórios em função da sua origem [20]	8
Figura 2.3 – Tipos de crepitação	10
Figura 3.1 – Desempenho de um algoritmo face à anotação de referência	14
Figura 3.2 – Segmento de um som respiratório não anotado.	16
Figura 3.3 – Crepitações anotadas por cada profissional de saúde no segmento da Figura 3.2.	16
Figura 3.4 – Sobreposição das anotações da Figura 3.3	17
Figura 3.5 – Máximos das crepitações anotadas da Figura 3.4.	17
Figura 3.6 – Locais de um paciente sujeitos a auscultação.	20
Figura 4.1 – Forma de onda típica de uma crepitação segundo Murphy et al. [32]	22
Figura 4.2 – Parâmetros de caracterização de crepitações do domínio do tempo: <i>two-cycle duration</i> (2CD), <i>initial deflection width</i> (IDW) e <i>largest deflection width</i> (LDW).	23
Figura 4.3 – Diagrama de blocos global de um algoritmo de detecção de crepitações	24
Figura 4.4- Diagrama de blocos do algoritmo implementado por Vannuccini et al. [1].	29
Figura 4.5 – Representação da forma de onda de uma crepitação e da sua primeira derivada, juntamente com o método geométrico para descobrir o ponto de início t_s [1]	30
Figura 4.6 – Representação do módulo da primeira derivada (F _{DAV}) de um sinal, dos intervalos envolvidos no método e dos limiares T e T_w [1]	31
Figura 4.7 – Diagrama de blocos do algoritmo <i>Fractal Dimension</i> (FD)	33
Figura 4.8 –Som respiratório e correspondente FD [2].	34
Figura 4.9 – Fluxograma do Algoritmo de Detecção de Picos na FD (FD-PPA) [54]	35
Figura 4.10 –Som respiratório e correspondente FD e resultado final após a aplicação do algoritmo FD-PPA (FDPP=p) [2]	36
Figura 4.11 – Algoritmo proposto por Bahoura e Lu [4].	37
Figura 4.12 – Esquema da técnica de filtragem WPST-NST [4].	38
Figura 4.13 – Esquema do algoritmo de detecção de picos (CPD) [4].	42
Figura 5.1 – Teste preliminar do algoritmo Vannuccini et al.	47
Figura 5.2 – Parâmetros SE, PPV e F do algoritmo de Vannuccini et al. no repositório de teste.	48
Figura 5.3 – Teste preliminar do algoritmo de Vannuccini et al. alterado	51
Figura 5.4. – Parâmetros SE, PPV e F do algoritmo de Vannuccini et al. alterado.	52
Figura 5.5 – Teste preliminar do algoritmo de Hadjileontiadis e Rekanos.	55
Figura 5.6 – Parâmetros SE, PPV e F do algoritmo de Hadj. e Rekanos no repositório de teste.	56
Figura 5.7 – Teste preliminar do algoritmo FD de Sevcik.	59
Figura 5.8 – Parâmetros SE, PPV e F do algoritmo FD de Sevcik no repositório de teste.	60
Figura 5.9 – Parâmetros SE, PPV e F do algoritmo de Bahoura e Lu no repositório de teste.	63
Figura 6.1 – Parâmetros SE, PPV e F do algoritmo SG-FD no repositório de teste.	66
Figura 6.2 – Distribuição de limiares dos vários algoritmos utilizados nos gráficos da Figura 6.3, da Figura 6.4 e da Figura 6.5.	68
Figura 6.3 – Curva do valor médio de SE obtida por acordo entre algoritmos	69
Figura 6.4 – Curva do valor médio de PPV obtida por acordo entre algoritmos.	69
Figura 6.5 – Curva do valor médio de F obtida por acordo entre algoritmos	70
Figura A.1 – Janela ‘Sistema de Detecção de Crepitações’	78
Figura A.2 – Botão ‘Menus’	78
Figura A.3 – Janela ‘Acordo entre Algoritmos de Detecção de Crepitações’	79
Figura A.4 – Menu ‘Acordo entre Clínicos’	80
Figura A.5 – Menu ‘Algoritmos de Detecção’	80

Figura A.6 – Executar vários limiares.....	81
Figura A.7 – Executar em apenas um limiar.....	81
Figura A.8 – Menu ‘Limiares’	81
Figura A.9 – Menu ‘Acordo entre Algoritmos’	82
Figura A.10 – Menu ‘Limiar Máximo por Acordo’	83
Figura A.11 – Menu de ‘Acordo’ com limiares óptimos e de máximos	83

Lista de Tabelas

Tabela 3.1 – Repositório Piloto	20
Tabela 4.1 – Valores de referência de IDW e 2CD (em ms) segundo várias fontes.	22
Tabela 4.2 – Valores de referência de IDW, 2CD e LDW segundo Hoevers e Loudon	23
Tabela 4.3 – Desempenho dos filtros de separação WPST-NST e WT-ST [4]	43
Tabela 4.4 – Desempenho da detecção de crepitações com o algoritmo de Bahoura e Lu [4]	44
Tabela 5.1 – Desempenho óptimo do algoritmo de Vannuccini et al.....	49
Tabela 5.2 – Pontos de máximo desempenho do algoritmo de Vannuccini et al.....	49
Tabela 5.3 – Desempenho óptimo do algoritmo de Vannuccini et al. alterado.....	53
Tabela 5.4 – Pontos de máximo desempenho do algoritmo de Vannuccini et al. alterado.....	53
Tabela 5.5 – Desempenho do algoritmo de Hadji. e Rekanos por aplicação do limiar óptimo.....	57
Tabela 5.6 – Pontos de máximo desempenho do algoritmo de Hadjileontiadis e Rekanos.	57
Tabela 5.7- Desempenho do algoritmo de FD de Sevcik por aplicação do limiar óptimo.	61
Tabela 5.8 – Pontos de máximo desempenho do algoritmo FD de Sevcik	61
Tabela 5.9 – Desempenho do algoritmo de Bahoura e Lu por aplicação do limiar óptimo.....	64
Tabela 5.10 – Pontos de máximo desempenho do algoritmo de Bahoura e Lu.....	64
Tabela 6.1 – Desempenho do acordo entre algoritmos por aplicação do conjunto de limiares que obtém o máximo valor médio de F.	70
Tabela 6.2 – Valores médios de SE, PPV e parâmetro F de cada algoritmo.	71
Tabela 6.3 – Desempenho do acordo entre os limiares óptimos dos 4 algoritmos.	71

Glossário

AR	Auto-Regressivo
ATS	<i>American Thoracic Society</i>
CE	Comunidade Europeia
CORSA	<i>Computerized Respiratory Sound Analysis</i>
2CD	<i>Two Cycle Duty</i>
EMD	<i>Empirical Mode Decomposition</i>
ERS	European Respiratory Society
F	Média Harmónica
FD	Dimensão Fractal
FDAV	Valor Absoluto da Primeira Derivada
FDD	Detector baseado em Dimensão Fractal
FD-PPA	Algoritmo de Detecção de Picos da FD
FIR	Resposta Impulsional Finita
FN	Falsos Negativos
FP	Falsos Positivos
FPI	Fibrose Pulmonar Idiopática
IDW	<i>Initial Deflection Width</i>
IRTI	Infecção Respiratória do Tracto Inferior (IRTI)
LDW	<i>Large Deflection Width</i>
PPV	Precisão
QMS	<i>Quadrature Mirror Filters</i>
SE	Sensibilidade
SG	Savitzky-Golay
SPA	Sons Pulmonares Adventícios
ST-NST	Estacionário – Não Estacionário
TEWA	Time Expanded Waveform Analysis
TP	Verdadeiro Positivo
WPT	<i>Wavelet Packet Transform</i>
WT	<i>Wavelet Transform</i>

1. Introdução

Este primeiro capítulo visa apresentar a motivação e o contexto da análise e processamento de sons pulmonares, assim como dar a conhecer os objectivos do trabalho desenvolvido e a estrutura desta dissertação.

1.1. Motivação e Contexto

Actualmente, milhões de pessoas em todo o Mundo sofrem de patologias respiratórias. Devido às limitações apresentadas pelas técnicas actuais de diagnóstico e monitorização destas patologias existe cada vez mais interesse no desenvolvimento de métodos automáticos de detecção de sons pulmonares adventícios (SPA) tirando partido das novas tecnologias de computação e processamento digital de sinal. Uma vez que poderão ser utilizados pelos profissionais de saúde como instrumento para monitorizar e avaliar a eficácia das terapias respiratórias, o que neste momento só é possível com recurso a meios radiológicos dispendiosos com elevada dose de radiação ionizante associada. De facto, o número de SPA presentes numa auscultação é um importante indicador de gravidade de uma patologia respiratória [5, 6]. Para além do número, também os locais onde são gerados, os instantes de ocorrência dentro do ciclo respiratório (fase inspiratória ou expiratória), as propriedades específicas das formas de onda e o próprio conteúdo espectral podem ser (e têm sido) exploradas como factores de diagnóstico [7].

Ao diminuir a necessidade de intervenção humana e o nível de especialização requerido, um detector/classificador automático de SPA também facilitaria a monitorização (eventualmente remota) de patologias respiratórias. Futuramente, com base na análise automática de parâmetros como os mencionados na secção 4.1, poderá ser possível desenvolver sistemas inteligentes capazes de reconhecer determinadas patologias. À medida que a sua fiabilidade aumente, estes sistemas

tornar-se-ão de uso cada vez mais comum na prática clínica.

1.2. Objectivos

Esta dissertação está directamente relacionada com dois projectos de investigação em curso:

- ‘Sons pulmonares adventícios como indicadores de severidade e recuperação de patologia respiratória e localização de secreções’;
- ‘Sounds4Health’.

Estes projectos, financiados respectivamente pela FCT e pelo QREN, envolverão a análise de milhares de ficheiros de sons respiratórios (cuja recolha se encontra em curso) para a detecção de SPA (crepitações e sibilâncias).

O trabalho aqui descrito explora a implementação e validação de algoritmos automáticos de detecção de crepitações, visando encontrar a solução mais indicada para os projectos mencionados.

1.3. Estrutura da dissertação

Após este capítulo introdutório, esta dissertação prossegue no Capítulo 2, com uma breve apresentação do sistema respiratório humano e dos tipos de sons respiratórios. No Capítulo 3, são discutidas as características que um repositório de sons respiratórios deve possuir. É explicada a importância do repositório se encontrar devidamente anotado por um painel de anotadores (profissionais de saúde) para obter referências credíveis (‘gold standards’) para a avaliação de desempenho dos algoritmos.

O Capítulo 4 apresenta o esquema global de um detector de crepitações. É apresentada uma revisão aprofundada dos métodos propostos na literatura e descritos detalhadamente os escolhidos para implementação.

No Capítulo 5 descreve-se e explica-se com grande detalhe a implementação dos métodos escolhidos e faz-se a avaliação do seu desempenho, com base no repositório de sons e correspondentes anotações de referência discutidos no Capítulo 3. Ainda no Capítulo 5, são referidas as modificações efectuadas nos algoritmos com o intuito de incrementar o seu desempenho.

No Capítulo 6 são explorados dois novos algoritmos: um resulta da combinação de técnicas já utilizadas; outro resulta da conjugação de todos os algoritmos implementados no Capítulo 5 por estabelecimento de um acordo entre eles.

Finalmente, no Capítulo 7 é feita uma análise global dos resultados obtidos e dos objectivos alcançados, que permite também identificar várias possibilidades de

trabalho futuro.

2. Sons Respiratórios

Neste capítulo, é apresentada uma breve exposição teórica sobre o sistema respiratório, as patologias respiratórias, as técnicas de diagnóstico usadas para a sua detecção e a classificação dos sons respiratórios.

2.1. Sistema Respiratório

O sistema respiratório é vital para o ser humano, pois é o responsável pelo fornecimento do oxigénio (O_2) que as células do nosso organismo consomem durante a produção de energia e também pela libertação do dióxido de carbono (CO_2) resultante do processo [8].

À repetição cíclica desta troca gasosa, em ciclos com uma duração típica de três a cinco segundos, dá-se o nome de respiração. É provocada por impulsos nervosos que estimulam o diafragma (músculo principal da respiração, situado entre o tórax e o abdómen) e os músculos intercostais de forma que a caixa torácica sucessivamente se dilate e contraia, fazendo assim o ar fluir por uma série de canais (vias aéreas) respectivamente para dentro e para fora dos pulmões [9]. É esta ventilação que permite a troca de gases entre os pulmões e o sangue (respiração externa). O sangue transporta até às células o O_2 necessário para a produção de energia. Nas células decorre uma nova troca de gases (respiração interna) [8, 10], que lhes permite utilizar o O_2 para produzir a energia necessária à sua actividade. Para além da troca de O_2 com CO_2 , a respiração é importante para manter os níveis normais de pH do sangue bem como para regular a temperatura corporal [10, 11].

O ar que respiramos faz a sua entrada pelas narinas ou pela boca e, após percorrer a faringe, a laringe e a traqueia, divide-se entre os brônquios esquerdo e direito, cada um dos quais conduz ao respectivo pulmão pelo hilo pulmonar. Nos pulmões, o ar atravessa canais progressivamente mais estreitos até aos bronquíolos, terminando o

seu percurso em pequenos sacos denominados alvéolos. O percurso de saída é exactamente o mesmo, no sentido inverso (vide Figura 2.1) [11, 12]. Estas duas fases complementares designam-se respectivamente *inspiração* e *expiração*.




Figura 2.1 – Sistema Respiratório

2.2. Classificação das Patologias Respiratórias

As patologias do sistema respiratório dividem-se essencialmente em duas grandes categorias: doenças obstrutivas e doenças restritivas.

As doenças obstrutivas ocorrem devido a excessiva produção de muco que conduz à obstrução das vias aéreas. Como exemplos desta categoria de doenças destacam-se a asma, a bronquite crônica, a laringite crônica, o enfisema e as neoplasias da laringe. As doenças restritivas ocorrem por fibrose intersticial (i.e. cicatrização do tecido entre os vasos sanguíneos e os alvéolos pulmonares) ou inflamações que provocam endurecimento dos pulmões. São exemplos a sarcoidose, a fibrose pulmonar, a pneumonia, a insuficiência cardíaca congestiva, a tuberculose e a doença pulmonar reumatóide.

2.3. Diagnóstico e Monitorização

O diagnóstico de doenças respiratórias é uma área de grande importância. O diagnóstico através de sons respiratórios remonta pelo menos à Grécia Antiga: a técnica de auscultação pulmonar foi utilizada pelo próprio Hipócrates, considerado o pai da Medicina. Durante muitos séculos, o método usado para auscultar os sons

produzidos quer pelo coração quer pelo sistema respiratório, consistia em encostar directamente o ouvido à caixa torácica do paciente. A evolução da técnica de auscultação foi praticamente nula até ao século XIX. Em 1816, um médico francês, René Laennec, inventou um dispositivo a que chamou estetoscópio: tratava-se de um cilindro oco através do qual se podia ouvir encostando a extremidade oposta à caixa torácica do paciente [13, 14]. Esta nova ferramenta não invasiva de monitorização e diagnóstico melhorava muito a qualidade do sinal escutado, o que possibilitou a Laennec explorar e interpretar melhor os sons produzidos pelo sistema respiratório [14]. Desde então, o estetoscópio tem conhecido constante aperfeiçoamento, com o objectivo de melhorar a qualidade do sinal [15]; destaca-se o advento do estetoscópio bi-auricular, hoje, sem dúvida, o instrumento mais omnipresente na Medicina, quase um símbolo da profissão. A evolução tecnológica das últimas décadas conduziu naturalmente ao aparecimento de estetoscópios electrónicos digitais, que permitem aos profissionais de saúde não só obter sinais de auscultação com melhor qualidade como também armazená-los para futuras análises e comparações.

Apesar das constantes evoluções que o estetoscópio tem sofrido, a auscultação apresenta limitações:

- Depende da capacidade auditiva e da experiência do observador;
- A respiração gera sinais fora da gama de frequências audíveis pelo ser humano;
- Os mecanismos na origem dos sons respiratórios ainda não são inteiramente compreendidos;
- A identificação e classificação de sintomas patológicos nos sons respiratórios enferma de subjectividade;
- Há carência de estudos sobre a correlação entre sons auscultados e dados clínicos [15, 16].

Estas condicionantes indicam que só a auscultação pode não ser suficiente para detectar toda a informação de interesse. Daí a utilização de outras técnicas por parte dos profissionais de saúde, para confirmar ou auxiliar os seus diagnósticos e monitorizações [17]. As técnicas mais comuns são os testes de função respiratória (e.g. espirometria, análise do peso ou volume das secreções, gasimetria) e a imagiologia. No entanto, todas elas apresentam também limitações, discutidas em detalhe na literatura especializada. A análise computadorizada dos sons respiratórios é considerada uma via com grande potencial para ultrapassar tais limitações e facilitar o diagnóstico e monitorização das patologias respiratórias.

2.4. Classificação de Sons Respiratórios

A classificação de sons respiratórios é uma matéria pouco consensual. A Comunidade Europeia financiou um projecto intitulado *Computerized Respiratory Sound Analysis (CORSA)*, com o objectivo de desenvolver directrizes e parâmetros comuns não só para a classificação de sons respiratórios mas também para a sua aquisição, armazenamento e posterior processamento. Conduzido por Anssi Sovijärvi, este projecto contou com a adesão da *European Respiratory Society (ERS)* e envolveu a colaboração de investigadores e profissionais de saúde de sete países europeus (Bélgica, Reino Unido, Finlândia, França, Alemanha, Itália e Holanda) [18]. O trabalho foi bastante profundo, tendo envolvido a revisão de 1672 artigos, e culminou em 2000 com a publicação do relatório CORSA pela revista *European Respiratory Review* [18]. Apesar de não constituírem normas oficiais impostas por qualquer entidade, as recomendações do projecto CORSA vêm sendo, desde então, seguidas em grande parte dos trabalhos de investigação em sons pulmonares, como é o caso da presente dissertação.

Os sons respiratórios resultam das vibrações provocadas pelo fluxo de ar ao nível lobar ou dos brônquios [7]. Estas vibrações são transmitidas pelo tecido pulmonar e pela parede da caixa torácica, podendo ser ouvidas através de auscultação, com ou sem ajuda de um estetoscópio.

Segundo o projecto CORSA, os sons respiratórios podem ser classificados em sons *normais* e em sons *adventícios* [19], como mostra a Figura 2.2. As características de cada categoria serão discutidas nas próximas secções.

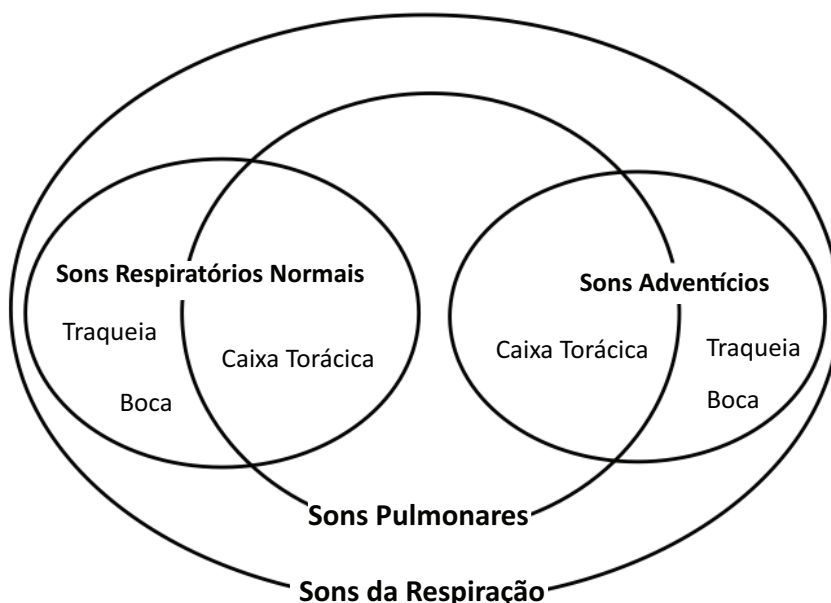


Figura 2.2 – Nomenclatura geral dos sons respiratórios em função da sua origem [20]

2.4.1. Sons Normais

Os sons respiratórios normais são sons escutados na boca, na traqueia e ao longo da caixa torácica (Figura 2.2). Apresentam um espectro de frequências alargado, consoante o local de auscultação [20].

2.4.1.1 Sons Traqueais

Os sons respiratórios normais escutados ao nível da traqueia são chamados *sons traqueais*. Assemelham-se em certa medida a ruído branco, por apresentarem uma largura de banda elevada (desde abaixo de 100Hz até acima de 1500Hz) e amplitude bastante variável. Exibem uma queda acentuada de energia acima dos 800Hz, aproximadamente [21]. São audíveis tanto na fase inspiratória como na fase expiratória, permitindo uma boa análise e distinção dos ciclos e fases respiratórias [19].

2.4.1.2 Sons Pulmonares

Os sons escutados na caixa torácica foram descritos por Laennec como “*a distinct murmur corresponding to the flow of air into and out of air cells*” [20]. A designação “murmúrios vesiculares” foi comum mas caiu em desuso, por inapropriada – não se pode gerar som ao nível alveolar (“vesicular”), pois aí o fluxo de ar é nulo.

A duração da fase inspiratória é inferior à da fase expiratória, com uma razão inspiração/expiração de aproximadamente 1:2. No entanto, a expiração chega a ser descrita como praticamente silenciosa [7]. Comparativamente aos traqueais, os sons pulmonares podem considerar-se de baixa frequência, pois o seu espectro concentra-se entre os 100 e os 250Hz. Os pulmões e os músculos respiratórios funcionam como um filtro passa-baixo com frequência de corte aproximadamente a 250Hz [7]; acima deste ponto, a atenuação é rápida, a uma taxa de 10 a 20 db por oitava. Mesmo assim, podem ser detectados sons normais a frequências superiores a 1000Hz, se forem utilizados microfones com alta sensibilidade numa sala com ruído controlado [22]. Infelizmente, estas bandas de frequência ainda contêm ruído provocado pelos músculos respiratórios e pelo coração [7].

2.4.2. Sons Pulmonares Adventícios (SPA)

Os sons pulmonares adventícios são sons respiratórios adicionais que se sobrepõem aos sons respiratórios normais [20]. Podem ser divididos em dois subgrupos principais: sons *contínuos* ou *estacionários* e *descontínuos* ou *não-estacionários*. Os

primeiros são conhecidos como *sibilâncias* (em inglês *wheezes*). Os sons descontínuos não têm designação consensual entre os clínicos [23]: usam-se os termos *fervores* e *crepitações*, que correspondem, respectivamente, às palavras inglesas *rales* e *crackles*. Esta última predomina, a avaliar pelos estudos de A.R. Nath [24] e G.R. Epler [25], pela opção da American Thoracic Society (ATS) [26] e pelo facto de o termo *rales* ser raramente encontrado na literatura mais recente. Por isso, optou-se nesta dissertação pelo termo *crepitações*.

2.4.2.1 Crepitações

As crepitações são descritas como sons explosivos, transitórios de curta duração (<20ms). A sua gama de frequências é alargada, variando dos 100 aos 2000 Hz, chegando por vezes a ser ainda mais elevada [7]; a sua ocorrência é mais notada na fase inspiratória do que na fase expiratória [27], sendo classificadas em dois tipos: finas (curta duração) e grossas (longa duração) [15, 19] vide Figura 2.3.




Figura 2.3 – Tipos de crepitação

As crepitações finas são associadas a doenças fibróticas como a fibrose pulmonar idiopática (FPI), à pneumonia e à insuficiência cardíaca congestiva [25]. Compõem-se de frequências altas e tendem a ocorrer a partir do meio da fase inspiratória [7]. Crê-se que têm origem na abertura repentina das vias aéreas [15].

As crepitações grossas são sinais de baixa frequência. Ocorrem normalmente no início da inspiração e, por vezes, também na expiração. A sua origem deve estar associada ao borbulhar de líquido nas vias aéreas [15]. Indiciam obstrução das vias aéreas, sendo geralmente associadas a patologias respiratórias como a bronquite crónica e bronquiectasia [25].

2.4.2.2 Sibilâncias

As sibilâncias são sons adventícios contínuos, muitas vezes audíveis mesmo sem auscultação, em que se pode distinguir um tom (*pitch*). Podem aparecer em qualquer instante do ciclo respiratório e com amplitudes muito variadas [19]. Na sua origem estão vibrações das paredes das vias aéreas com cadência e intensidade acima de certos limiares [28]. Apresentam uma vasta gama de frequências possíveis. Segundo o projecto CORSA [7], para poder ser classificado como sibilância, um som adventício deve ter frequência fundamental (*pitch*) superior a 100Hz e duração superior a 100ms. A transmissão do som é mais eficiente ao longo das próprias vias aéreas do que através dos tecidos que as separam da superfície da caixa torácica, que funcionam como um filtro passa-baixo, como já foi explicado no fim da secção 2.4.1. Desta forma, as componentes do sinal de frequências mais altas são melhor captadas por auscultação na traqueia.

As sibilâncias são classificadas como monofónicas ou polifónicas consoante contenham, respectivamente, uma ou mais frequências fundamentais.

3. Anotação de Sons Respiratórios

O objectivo principal desta dissertação é desenvolver algoritmos automáticos de detecção de crepitações. Como a avaliação de desempenho é uma componente indispensável desse trabalho, começa-se por discutir os parâmetros utilizados para esse efeito. É explicada a necessidade de anotações de referência credíveis e transparentes para basear a avaliação e descrito o esforço realizado para as obter. Este esforço passa pela criação de repositórios de sons respiratórios, desenvolvimento de aplicações computacionais amigáveis para anotação dos ficheiros e geração de anotações de referência com base em adequados critérios de acordo entre anotadores.

3.1. Avaliação de Desempenho (Validação)

De uma forma geral, são aplicáveis à detecção de crepitações os parâmetros tradicionalmente utilizados na avaliação de desempenho de classificadores [29]. Nesta dissertação dá-se particular ênfase à *sensibilidade* (*SE*) e à *precisão* (*positive predictive value* - *PPV*), normalmente expressos em percentagem. Trata-se de razões entre o número de crepitações correctamente detectados por um dado algoritmo (*true positives* - *TP*) e, respectivamente:

- O número total do tipo de crepitações efectivamente existentes, que inclui as não detectadas (*false negatives* – *FN*):

$$SE = \frac{TP}{TP + FN} \quad \text{Equação 3.1.1}$$

- O número total de crepitações detectadas, que inclui as que foram incorrectamente detectadas (*false positives* – *FP*):

$$PPV = \frac{TP}{TP + FP} \quad \text{Equação 3.1.2}$$

Os parâmetros TP, FP e FN estão ilustrados no diagrama de Venn da Figura 3.1.




Figura 3.1 – Desempenho de um algoritmo face à anotação de referência

É desejável que tanto a sensibilidade (SE) como a precisão (PPV) sejam tão elevadas quanto possível, pelo que a média entre elas constitui uma interessante métrica de desempenho. Existem várias formas alternativas de calculá-la, desde logo a média aritmética (A) e a média geométrica (G):

$$A = \frac{SE + PPV}{2} \quad \text{Equação 3.1.3}$$

$$G = \sqrt{SE \cdot PPV} \quad \text{Equação 3.1.4}$$

Neste trabalho usaremos a chamada *média harmónica* (parâmetro F), que combina as duas [30]:

$$F = \frac{G^2}{A} = \frac{\sqrt{SE \cdot PPV}^2}{\frac{SE + PPV}{2}} = 2 \times \frac{SE \times PPV}{SE + PPV} \quad \text{Equação 3.1.5}$$

3.2. Anotações de Referência

O cálculo dos parâmetros apresentados na secção 3.1 exige, obviamente, que se disponha de anotações de referência (*gold-standards*). Este aspecto tem recebido insuficiente atenção por parte dos investigadores nesta área. Por isso, um dos objectivos dos projectos FCT e QREN com que esta dissertação está relacionada é justamente desenvolver procedimentos e métodos que conduzam ao estabelecimento de referências construídas de forma transparente e credível. Devido à inevitável subjectividade do julgamento de anotadores humanos, elas devem resultar de acordo estatístico entre um número tão elevado quanto possível de anotações realizadas por

profissionais de saúde e os *critérios de acordo* devem ser claramente definidos. Segue-se uma explicação detalhada do processo seguido para construir as anotações de referência usadas no teste dos algoritmos implementados.

3.2.1. Anotação de Crepitações

Como se pretende usar repositórios extensos anotados pelo maior número possível de profissionais de saúde, torna-se imprescindível dispor de uma aplicação computacional completa e eficaz para anotação. O trabalho de anotação exige concentração e é naturalmente moroso, pois pode haver centenas de crepitações num ficheiro de poucos segundos de duração. Por outro lado, o público-alvo (médicos, enfermeiros, fisioterapeutas...) caracteriza-se por, de um modo geral, possuir agendas muito sobrecarregadas e poucos conhecimentos de programação. É necessário garantir uma interface com o utilizador amigável: a operação deve ser fácil e intuitiva. Neste contexto, foi desenvolvido, no âmbito do projecto *Sounds4Health*, um programa para anotação de ciclos respiratórios e sons adventícios (crepitações e sibilâncias) em sons respiratórios obtidos por estetoscopia. A anotação é efectuada directamente sobre as formas de onda visualizadas, que é simultaneamente possível escutar. A velocidade de reprodução áudio é controlável pelo utilizador e sincronizada com o cursor de visualização [31].

3.2.2. Acordo entre Anotadores

A utilização da plataforma de anotação permite que cada som respiratório seja anotado por um quadro de profissionais de saúde, possibilitando a criação de anotações de referência para cada som. Para gerar essas referências é necessário aplicar critérios de acordo. A Figura 3.2 representa um segmento de som respiratório sem anotações. A anotação consiste na indicação dos instantes de início e fim, mas, como seria de esperar (vide exemplo - Figura 3.3 e Figura 3.4), só por mero acaso eles são coincidentes nas várias anotações, sem que isso indique necessariamente desacordo.




Figura 3.2 – Segmento de um som respiratório não anotado.






Figura 3.3 – Crepitações anotadas por cada profissional de saúde no segmento da Figura 3.2.




Figura 3.4 – Sobreposição das anotações da Figura 3.3

Considerou-se, por isso, que a identificação das crepitações, para este efeito, não poderia ser realizada directamente com base nesses pontos. A forma encontrada para tornar o problema foi identificar a crepitação pelo seu pico (em valor absoluto) – vide Figura 3.5.




Figura 3.5 – Máximos das crepitações anotadas da Figura 3.4.

Para comprovar que a localização do máximo da crepitação seria uma condição adequada para identificar acordo, foram imaginados cenários que os anotadores poderiam gerar:

- Anotações sem qualquer intersecção – desacordo.
- Anotações com intersecção não nula e com máximo no mesmo ponto
Figura 3.4 – acordo.
- Anotações com intersecção não nula mas máximos em pontos diferentes – desacordo.

Decidida a utilização do ponto máximo de uma crepitação como condição para o estabelecimento do acordo, foi desenvolvido um algoritmo em *MatLab* (vide Anexo A), compreendendo os seguintes passos:

- (1) É lido o som respiratório ($x[n]$) e criado um vector inicializado a 0 ($V_{Max}[n]=0$), em que n representa o número de amostras do som respiratório;
- (2) É obtido o valor absoluto do som respiratório ($abs(x[n])$).
- (3) São percorridas todas as anotações ($i=1,...,TotalAnotadores$). Em cada uma (An) são encontradas, dentro de cada crepitação anotada, as amostras de máximo (em valor absoluto) e é criado um vector de n amostras onde:

$$An_i[n] = \begin{cases} 1 & \max[InicioCrepitacao_i(k), FimCrepitacao_i(k)] \\ 0 & else \end{cases}$$

$$InicioCAn_i\{n\} = InicioCrepitacao_i(k), k = 1, ..., CrepAnot_i$$

$$FimCAn_i\{n\} = FimCrepitacao_i(k), k = 1, ..., CrepAnot_i$$

Equação 3.2.1

$InicioCrepitacao_i$ = Início de uma crepitação anotada pelo anotador i

$FimCrepitacao_i$ = Fim de uma crepitação anotada pelo anotador i

$InicioCAn_i$ = Inícios das crepitações anotadas pelo anotador i

$FimCAn_i$ = Fins das crepitações anotadas pelo anotador i

$CrepAnot_i$ = Total de crepitações anotadas pelo anotador i

- (4) É calculado o somatório dos vectores obtidos para cada anotador:

$$V_{Max}[n] = \sum_{i=1}^{T_{An}} An_i[n]$$

Equação 3.2.2

$$T_{An} = Total\ Anotadores$$

- (5) O vector V_{Max} é percorrido para encontrar amostras cujo valor represente uma concordância por maioria (CM – adoptou-se o critério de maioria simples, mas seria fácil escolher outro). Cada ponto encontrado indica uma crepitação de referência, cujos início (CF_{Inicio}) e o fim (CF_{Fim}) são definidos pela média entre os anotadores em acordo:

$$if\ V_{Max}[n] \geq CM$$

$$T_{CA} = T_{CA} + 1$$

$$CF_{numero} = T_{CA}$$

$$CF_{Inicio}[T_{CA}] = \frac{\sum_{i=1}^{AnotConc} InicioCrepitacaoAn_i\{n\}}{AnotConc}$$

$$CF_{Fim}[T_{CA}] = \frac{\sum_{i=1}^{AnotConc} FimCrepitacaoAn_i\{n\}}{AnotConc}$$

Equação 3.2.3

CM = Concordância por maioria

T_{CA} = Total de crepitações em Acordo

$AnotConc$ = Anotadores em Acordo no pico n

- (6) No final é armazenado um ficheiro com a anotação de acordo.

Este algoritmo foi utilizado na interface de detecção de crepitações desenvolvida para os testes de avaliação descritos nos Capítulos 5 e 6 (vide Anexo A).

3.3. Repositório de Estudo

Para além do processo de obtenção das anotações de referência em si, o repositório que lhe serve de base também é um factor decisivo para a credibilidade da avaliação. Um repositório deve:

- Ser extenso, abrangendo pacientes com diferentes patologias e também pessoas saudáveis, numa gama alargada de idades, tanto do sexo masculino como do sexo feminino.
- Possuir ficheiros adquiridos em condições técnicas documentadas, de preferência constantes.
- Possuir informação dos pacientes.

Dos repositórios encontrados na literatura, o mais extenso é o utilizado por Murphy [32] (100 sons respiratórios). Outros autores [2, 4] recorrem a repositórios de 20 sons.

Grande parte dos repositórios encontra-se anotado por um único profissional de saúde, o que está longe de ser ideal. Acresce que tanto os repositórios como as anotações de referência não se encontram disponíveis para a comunidade científica, o que dificulta grandemente a replicação de testes e comparação de resultados.

O estudo-piloto de aquisição de sons respiratórios em curso num dos projectos mencionados no preâmbulo da secção 3.2 contempla a aquisição de dados de 100 pacientes. Cada paciente é auscultado em sete locais com um estetoscópio digital (vide Figura 3.6). Em cada local são armazenadas 3 auscultações, obtendo-se portanto, por cada paciente, 21 sons respiratórios. Como se prevê a repetição da auscultação em dois momentos, o repositório será constituído por 4200 sons respiratórios. Os pacientes participantes do projecto são adultos (≥ 18 anos) diagnosticados com Infecção Respiratória do Tracto Inferior (IRTI).




Figura 3.6 – Locais de um paciente sujeitos a auscultação

Os sons respiratórios têm uma duração de 25 segundos e são amostrados a 44100Hz.

Como esta aquisição de dados está ainda em curso, o trabalho desenvolvido nesta dissertação é feito sobre um repositório piloto constituído por 10 sons respiratórios, enumerados na Tabela 3.1. Trata-se de excertos dos ficheiros adquiridos, com duração de 10 segundos. Cinco deles provêm de pacientes com fibrose quística e os restantes cinco de pacientes com pneumonia. O repositório foi devidamente anotado por 3 profissionais de saúde ligados ao projecto em causa.

Som Respiratório	Patologia
Cr_LR1_1_processed	Fibrose Quística
Cr_LR1_2_1_processed	Fibrose Quística
Cr_LR1_2_2_processed	Fibrose Quística
Cr_LR1_3_processed	Fibrose Quística
Cr_LR2_1_processed	Fibrose Quística
c_p1_b1_PL_processed	Pneumonia
c_p1_b1_Tc_processed	Pneumonia
c_p3_b1_Ll_processed	Pneumonia
c_p3_b1_Lr_processed	Pneumonia
c_p6_b1_Pr_processed	Pneumonia

Tabela 3.1 – Repositório Piloto

4. Detecção e Classificação de Crepitações

Este capítulo discute os parâmetros utilizados na caracterização de crepitações e relembra as principais motivações para o desenvolvimento de algoritmos de detecção e classificação automática. É apresentado o esquema global de tais algoritmos e passam-se em revista as principais propostas que têm sido apresentadas na literatura.

4.1. Caracterização

Como já foi mencionado no capítulo anterior, as crepitações são SPA descontínuos, explosivos, transitórios de curta duração ($<20\text{ms}$) [7], comumente classificadas sob dois tipos: crepitações finas (*fine*) e grossas (*coarse*).

Ao longo dos anos, face ao desenvolvimento das tecnologias de computação que abrem caminho à automatização do processamento de dados, vários investigadores têm procurado estabelecer os parâmetros mais adequados para caracterizá-las de forma objectiva. Um dos estudos mais destacados neste sentido deve-se a Murphy et al. [33]; a sua técnica de análise da forma de onda (*TEWA –Time-expanded waveform analysis*), envolve a inspecção visual de gráficos de elevada resolução temporal (eixo de tempo à escala 3m:1s).

Murphy et al. [32] tipificaram a ‘verdadeira’ crepitação – vide Figura 4.1 –, definindo-a como uma onda transitória com as seguintes características:

- três a dezasseis passagens por zero;
- máxima amplitude superior ao dobro da do sinal base;
- deflexão inicial abrupta;
- picos sucessivamente mais afastados no tempo.




Figura 4.1 – Forma de onda típica de uma crepitação segundo Murphy et al. [32]

Na sua primeira análise, Murphy et al. reconheceram a distinção entre crepitações do tipo *grosso*, observadas em pacientes com pneumonia, e do tipo *fino* (menor duração e frequências mais elevadas), observadas em pacientes com fibrose pulmonar [19, 33], mas não estabeleceram qualquer parâmetro objectivo de classificação.

O estudo das características da forma de onda prosseguiu e Holford [34] definiu os parâmetros mais frequentemente adoptados para a classificação das crepitações; trata-se de duas propriedades no domínio do tempo: a *largura da deflexão inicial* (IDW – *Initial Deflection Width*) e a duração dos dois primeiros ciclos a partir do início da primeira deflexão (2CD – *Two Cycle Duration*), ambas ilustradas na Figura 4.2. Desde então, vários valores de referência têm sido sugeridos para estes parâmetros; a Tabela 4.1 apresenta alguns exemplos.

	Holford [34]		A.Cohen [35]		CORSA [18]		ATS [36]	
Tipo de crepitação	IDW	2CD	IDW	2CD	IDW	2CD	IDW	2CD
Fina	0,92	6	0,9	6	-	<10	0,7	5
Grossa	1,25	9,32	1,25	9,5	-	>10	1,7	10

Tabela 4.1 – Valores de referência de IDW e 2CD (em ms) segundo várias fontes.




Figura 4.2 – Parâmetros de caracterização de crepitações do domínio do tempo: *two-cycle duration* (2CD), *initial deflection width* (IDW) e *largest deflection width* (LDW).

Hoevers e Loudon [37] exploraram um terceiro parâmetro baseado na análise da forma de onda no domínio do tempo, a duração da deflexão de máxima amplitude (LDW – *Largest Deflection Width*), também ilustrada na Figura 4.2. Os valores de referência obtidos por estes autores para os parâmetros IDW, 2CD e LDW em cada tipo de crepitação encontram-se na Tabela 4.2.

Tipo de crepitação	IDW	2CD	LDW
Fina	0,5	3,3	1,23
Grossa	1	5,1	2,27

Tabela 4.2 – Valores de referência de IDW, 2CD e LDW segundo Hoevers e Loudon

Eles concluíram que o LDW permitia resultados superiores aos obtidos com base nos parâmetros IDW e 2CD na distinção entre crepitações finas e grossas. Estudos posteriores evidenciaram a sua mais-valia como auxiliar de diagnóstico e monitorização de doenças respiratórias [38, 39]. Uma das grandes vantagens deste parâmetro prende-se com a dificuldade de encontrar exactamente o ponto de início de uma crepitação em determinadas situações, o que pode prejudicar a correcta medição de IDW e 2CD [5].

Houve esforços no sentido de encontrar parâmetros para a classificação de crepitações através de factores não directamente relacionados com as suas propriedades no domínio do tempo. No entanto, estes não se revelaram vantajosos;

por exemplo, a análise espectral recorrendo à transformada rápida de Fourier é tecnicamente difícil de aplicar a formas de onda de reduzida duração, como é o caso das crepitações [19, 40].

4.2. Detecção automática

4.2.1. Estrutura Geral dos Algoritmos

A Figura 4.3 seguinte representa o esquema global de um algoritmo de detecção e classificação de crepitações.

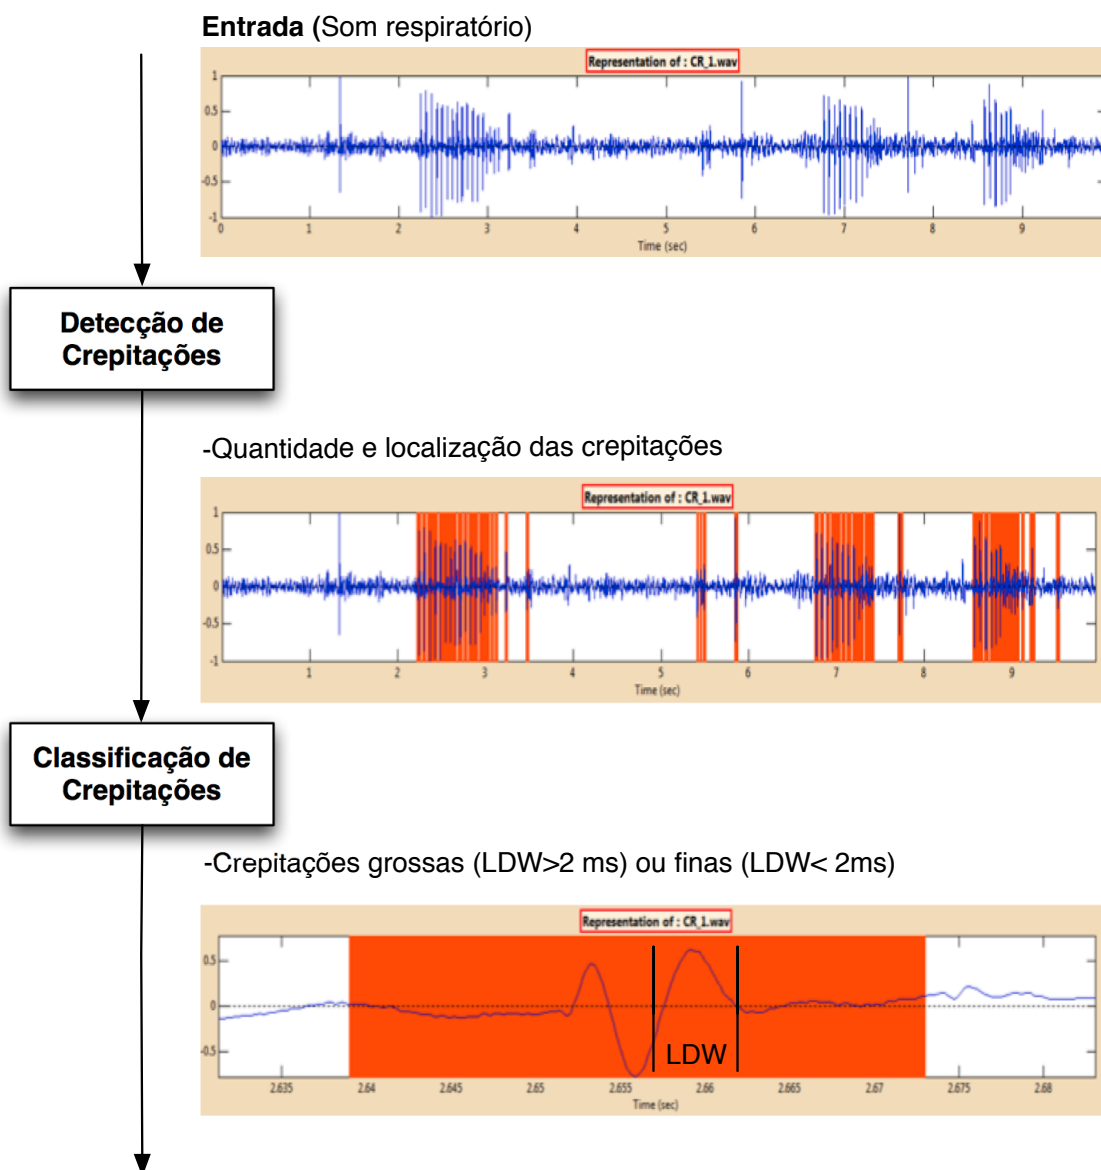


Figura 4.3 – Diagrama de blocos global de um algoritmo de detecção de crepitações

A entrada é um ficheiro contendo uma auscultação previamente gravada. O bloco de *detecção* trata de registar a ocorrência de crepitações, anotando o início e o fim de cada uma, permitindo assim a sua contagem. Normalmente, como é patente nos algoritmos que foram implementados (vide Capítulo 4), existe uma fase de filtragem para supressão de ruído ou separação das componentes estacionárias antes da aplicação do algoritmo de detecção propriamente dito. Todos os algoritmos envolvem a especificação de um ou mais limiares (*thresholds*) que determinam os seus desempenhos e em particular a sua sensibilidade (SE).

O bloco de *classificação* discrimina crepitações finas e grossas com base em parâmetros do tipo discutido na secção 4.1.

4.2.2. Evolução Histórica

O desenvolvimento de algoritmos para sistemas computadorizados de detecção e classificação de crepitações é uma tarefa complexa por várias razões, nomeadamente:

- baixa relação de magnitude entre as crepitações e os sons respiratórios normais;
- possibilidade de sobreposição de crepitações;
- distorção da forma de onda das crepitações pelos sons respiratórios normais e consequente dificuldade de determinar os parâmetros que caracterizam as crepitações como IDW, 2CD e LDW [41].

Têm por isso sido exploradas diversas técnicas para o efeito. Entre elas um método implementado por Murphy [32], que obteve um bom acordo entre o número de crepitações escutadas por dois especialistas e o número de crepitações detectadas [42].

Ono et al. [43] propuseram a aplicação de filtros digitais não lineares (filtros FST-NST) para efectuar a separação do som respiratório em duas componentes: não-estacionária (crepitações) e estacionária (sons respiratórios normais e sibilâncias). Os testes de validação apresentaram envolveram a análise de crepitações em 6 pacientes com fibrose pulmonar.

Kaisla [44] propôs outro método baseado na análise de espectrogramas (representação tempo/frequência), em que as crepitações podem ser detectadas como picos estreitos. Os testes de validação tomaram como referência anotações feitas por dois especialistas usando o método TEWA em registos de som respiratório de 20 adultos: 10 com alveolite fibrosa (*fibrosing alveolitis* – FA) e 10 com bronquiectasia (BE). Os parâmetros SE e PPV foram estimados respectivamente em 89% e 88% para os pacientes com FA e em 80% e 83% para os pacientes com BE.

Vannuccini et al. [1] apresentaram um método de detecção no domínio do tempo,

mas operando sobre o valor absoluto da primeira derivada do sinal, obtida através da aplicação de filtros Savitzky-Golay [45]. Os testes de validação mencionados no artigo envolveram pacientes com fibrose pulmonar idiopática (FPI). O artigo reclama SE e precisão (SP – a definição apresentada para este parâmetro não é a convencional) respectivamente 84% e 89%, obtidas por comparação com anotações realizadas por um especialista usando o método TEWA e auscultação.

No sentido de melhorar os resultados obtidos por Ono et al. [43], Hadjileontiadis combinou-o com modelos auto-regressivos (AR) de elevada ordem estatística. O conceito consiste em estimar a ordem dos modelos AR e os seus coeficientes recorrendo a estatísticas de terceira ordem com o objectivo de obter uma representação mais fidedigna da parte estacionária do sinal. Esta combinação possibilitou uma maior precisão e imunidade ao ruído [46].

O mesmo autor, agora em colaboração com Panas, também combinou o mesmo método com transformações por *wavelets* (WT) [47]. Usando coeficientes bastante rigorosos impostos pelos filtros *stationary-nonstationary* (ST-NST) a cada componente de cada decomposição, são criadas componentes de WT com diferentes pesos, permitindo a distinção entre as partes estacionária do sinal e não estacionária do sinal. A separação é assim conseguida por um processo iterativo de reconstrução-decomposição, baseado no peso que cada componente WT apresenta a cada iteração. Este método (*wavelet transform-based stationary-nonstationary filter*-WTST-NST) foi avaliado pela análise de crepitações finas em seis pacientes diagnosticados com fibrose pulmonar intersticial e crepitações grossas em cinco pacientes com bronquite crónica. Os resultados indicaram um algoritmo mais objectivo e preciso do que os apresentados até então. Outros investigadores também usaram as transformações por *wavelets* para a modelação e detecção de crepitações; destaca-se o trabalho de Kahya em várias co-autorias [48-50].

Prosseguindo no domínio das *wavelets*, alguns autores, como Bahoura e Lu [4], recorreram às transformações por *wavelet packets*.

A combinação dos filtros ST-NST com filtros *fuzzy* (*generalized fuzzy rule-based stationary-nonstationary* – GFST-NST), foi proposta por Hadjileontiadis e Tolia [51]. O método envolve duas redes adaptativas baseado na interferência *fuzzy* dos sistemas. O processo de treino das redes adaptativas, utiliza os resultados obtidos pelo método anterior (WTST-NST). A validação foi feita com os mesmos ficheiros. O desempenho dos dois métodos mostrou-se equivalente. O método GFST-NST é mais rápido, mas envolve um processo de aprendizagem, o que implica a necessidade de dispor de uma extensa base de dados sem quaisquer erros de anotação, que causariam uma aprendizagem defeituosa. Outros investigadores também utilizaram filtros *fuzzy*, como é o caso de Mastorocostas e Theocharis [52],

que os aplicaram juntamente com redes neuronais.

Um método simples, rápido e bastante apelativo baseado na função de *fractal dimension* (FD) para detecção em tempo real de crepitações foi também proposto por Hadjileontiadis e Rekanos [2]. A FD pode representar a complexidade de um sinal no domínio do tempo [4, 53]. Esta complexidade pode variar com a súbita ocorrência de sinais transitórios, como as crepitações. O autor salienta que o seu propósito não é identificar as características fractais dos sinais mas sim identificar as variações de complexidade, ou seja, identificar as partes não-estacionárias do sinal. Ao identificar estas partes, este método detecta muito eficientemente a localização e a duração das crepitações [54], não precisando portanto de fazer a separação do sinal na sua parte estacionária e não-estacionária. Utilizando os mesmos ficheiros usados em anteriores artigos de Hadjileontiadis, os testes de validação revelaram desempenho igualmente elevado, mesmo em presença de elevado ruído. Pela sua simplicidade, pelo seu baixo custo computacional, pela sua rapidez e pelo seu excelente desempenho o método *fractal dimension-based* (FD) é muito atractivo. É de referir que o algoritmo FD utilizado pelo autor foi o algoritmo proposto por Katz [55], mas existem mais algoritmos de FD descritos na literatura como é o caso do de Sevcik [56].

Como referido anteriormente, os autores Bahoura e Lu [4] propuseram como método de separação entre as partes não-estacionária e estacionária de um sinal respiratório os *wavelet packet transform-based stationary-nonsationary filters* (WPST-NST) [57]. Recorrendo a ficheiros do mesmo repositório utilizado por Hadjileontiadis, defendem que o seu método é 5 vezes mais rápido que o método WTST-NST [47] e com um desempenho muito semelhante. Além disso, afirmam que é capaz de preservar melhor as características não-estacionárias do sinal. Num trabalho posterior, após execução do método WPST-NST, aplicaram na parte não-estacionária do som respiratório o algoritmo de FD de Sevcik e um algoritmo de caracterização de crepitações, para obter eficientemente a localização e os parâmetros 2CD, TDW e LDW das crepitações [4].

Mais recentemente, Charleston-Villalobos et al. [58] e Hadjileontiadis [59] propuseram a análise de crepitações utilizando o algoritmo *Empirical Mode Decomposition* (EMD) [60]. O algoritmo EMD é intuitivo, i.e. a base da expansão é gerada de uma forma directa, *a posteriori* e adaptativa. A ideia base é que toda a informação é composta por simples modos intrínsecos de oscilações, representados por *Intrinsic Mode Functions* (IMFs). Ao contrário de uma simples função harmónica uma IMF possibilita a modulação da amplitude e da frequência; por isso, é muito mais geral. De acordo com Huang et al., uma IMF satisfaz duas condições: em toda a informação, o número de extremos e o número de passagens pela linha de

origem, devem ser iguais ou consecutivos; em qualquer ponto, o valor médio da envolvente é definido pelo máximo local e a envolvente definida pelo mínimo local é zero. O EMD considera os sinais nas suas escalas de oscilação, subtrai a oscilação mais rápida e prossegue iterativamente com o resíduo. Hadjileontiadis combinou os algoritmos EMD e FD e afirma que esta combinação oferece elevado desempenho, embora ligeiramente inferior ao obtido por aplicação do método FD.

Foram implementados no trabalho desenvolvido nesta dissertação o algoritmo proposto por Vannuccini et al. [1], o algoritmo FD de Hadjileontiadis e Rekanos [2] e o algoritmo WPST-NST de Bahoura e Lu [4]. A escolha destes algoritmos será devidamente explicada nas próximas secções. No capítulo seguinte será apresentada a sua implementação em *MatLab* bem como algumas modificações efectuadas no sentido de conseguir melhores desempenhos e também evitar certas dificuldades.

4.3. Algoritmo de Vannuccini et al.

Este é um dos primeiros métodos descritos na literatura para este efeito. Foi utilizado, nomeadamente, em [61]. Assim a sua implementação foi a tarefa inicial deste trabalho de mestrado.

4.3.1. Esquema Global

Este algoritmo é ilustrado no diagrama de blocos da Figura 4.4:

- No primeiro bloco é feita a filtragem do som respiratório para supressão de ruído por aplicação de filtros *Savitzky-Golay* (SG). A aplicação destes filtros também permite obter a primeira derivada do som respiratório;
- No terceiro bloco, o limiar T , cujo valor está relacionado com a amplitude, é comparado ao valor absoluto da primeira derivada (FDAV) do som respiratório (obtida no segundo bloco) para seleccionar zonas consideradas com probabilidade de conter crepitações (zonas de interesse). Caso essas zonas possuam uma duração maior que o limiar T_w (duração de uma crepitação), são descartadas;
- No último bloco, são identificadas as crepitações que verificam certas condições nas zonas de interesse, ilustradas na Figura 4.6:

Segue-se uma explicação detalhada das operações do algoritmo (vide Figura 4.4).

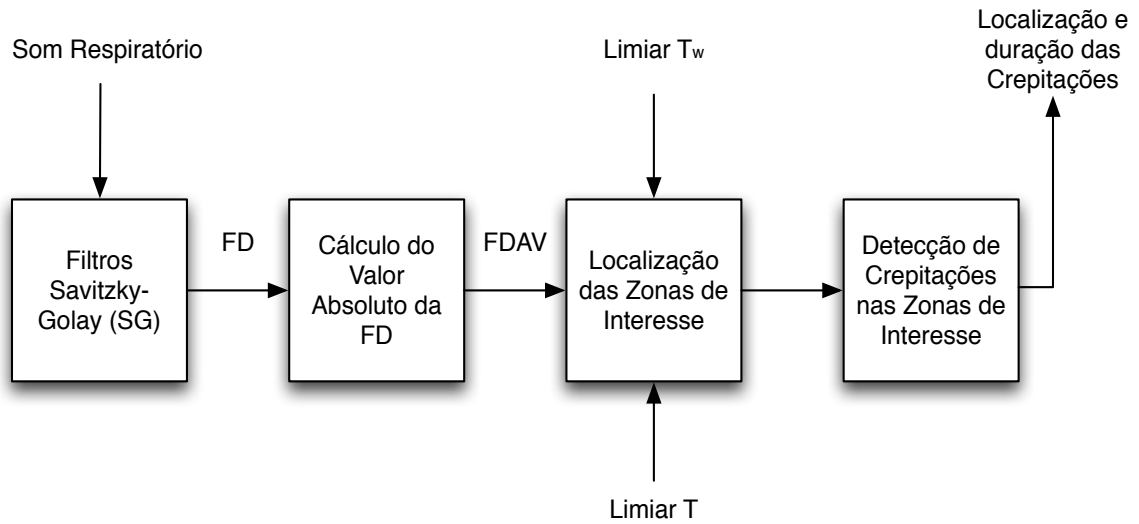


Figura 4.4- Diagrama de blocos do algoritmo implementado por Vannuccini et al. [1].

4.3.2. Parâmetros de Entrada

Os sons respiratórios utilizados pelos autores foram obtidos de quinze pacientes com fibrose pulmonar difusa idiopática (FDPI). Foi utilizada filtragem passa-alto a 60Hz (18dB/oitava) e digitalização com 16 *bits* de resolução e frequência de amostragem 8000Hz.

Não existe um método automático para a obtenção de T e T_w . O limiar T , associado à amplitude do som respiratório é crítico para o desempenho do algoritmo, mas só pode ser escolhido de forma empírica. O limiar T_w , associado à duração de uma crepitação, não é tão crítico como o limiar T . Tem que se ter em consideração que, se for muito pequeno, o algoritmo pode não conseguir detectar todas as crepitações; se for demasiado elevado, pode detectar uma só crepitação onde na realidade há mais. Assumindo que a duração de uma crepitação é geralmente inferior a 20ms, os autores consideraram que um bom valor seria 5 ms.

4.3.3. Filtragem Savitzky-Golay

Estes filtros FIR são utilizados quer para suavizar o som respiratório por filtragem passa-baixo, quer para obter a sua primeira derivada.

As especificações dos filtros são: o número de coeficientes n , o grau polinomial apropriado p , a ordem de derivação d (0 apenas para suavização) e a ordem do momento mais alto para preservar m . Para obtermos a derivada do som respiratório o valor de p tem de ser pelo menos 4. O valor de n deve ser entre 1 a 2 o tamanho da zona do som a preservar. O filtro pode ser desenhado para preservar o IDW. Considerando que o IDW do sinal tem cerca de 1 ms e como o som respiratório é

amostrado a 8000 Hz, isso significa que o IDW possui pelo menos 8 amostras; assim uma opção possível é $n=9$, $p=4$, $d=1$ e $m=2$.

A Figura 4.5 ilustra a aplicação do filtro SG para obtenção da 1ª derivada de uma crepitação.




Figura 4.5 – Representação da forma de onda de uma crepitação e da sua primeira derivada, juntamente com o método geométrico para descobrir o ponto de início t_s [1]

Na Figura 4.5, o primeiro máximo da derivada corresponde ao ponto de máxima inclinação na primeira deflexão da onda original. A intersecção da tangente nesse ponto com o eixo temporal constitui o início da crepitação (t_s).

Como a primeira derivada do som respiratório pode ser positiva ou negativa e o limiar T é sempre um valor positivo, o método requer o valor absoluto da primeira derivada do sinal (FDAV).

4.3.4. Localização das Zonas de Interesse

A FDAV do som respiratório é percorrida; inicia-se uma *zona de interesse* para pesquisa de crepitações quando o seu valor se torna superior ao limiar T ; começa então a avaliação dos intervalos t_{on} e t_{off} : t_{on} é o período em que a FDAV está acima de T e t_{off} é o período em que está abaixo:

$$t_{on} = \sum_i t_{on_i}$$

$$t_{off} = \sum_i t_{off_i}$$

Equação 4.3.1

A Figura 4.6 mostra estes intervalos e a sua correspondência com a FDAV do sinal. A acumulação de parcelas em t_{on} e t_{off} prossegue enquanto $t_{on} > t_{off}$ e $t_{on} + t_{off} < T_w$. O ponto em que esta condição deixa de se verificar define o final da zona de interesse.




Figura 4.6 – Representação do módulo da primeira derivada (FDAV) de um sinal, dos intervalos envolvidos no método e dos limiares T e T_w [1]

4.3.5. Detecção de Crepitações

As zonas de interesse são percorridas e em cada uma delas são testadas as seguintes condições:

- Existência de pelo menos três picos da FDAV no intervalo T_w . A posição dos picos corresponde aos pontos de máxima inclinação do som respiratório naquele intervalo (t_1 , t_2 e t_3 na Figura 4.6).
- Inclinação em t_2 superior à inclinação de t_1 e t_3 , ou seja, pico máximo da FDAV no ponto t_2 .
- Intervalos entre picos da FDAV progressivamente maiores: $t_1 - t_s < t_2 - t_1 < t_3 - t_2$

Se todas estas condições forem verificadas, está-se na presença de uma crepitação na zona de interesse avaliada.

4.3.6. Validação do Algoritmo

Na validação do algoritmo, os autores utilizaram como referência uma anotação realizada por um único profissional de saúde, com base nos critérios de Murphy [33] e na audição dos ficheiros. Foi calculada a SE (vide Equação 3.1.1) e um outro parâmetro que os autores designaram ‘especificidade’, definido pela Equação 4.3.3. Note-se que esta equação não corresponde à definição convencional deste parâmetro.

$$\text{TOT} = \text{TP} + \text{FN} \quad \text{Equação 4.3.2}$$

$$\text{SP} = 1 - \frac{\text{FP}}{\text{FN} + \text{TP}} \quad \text{Equação 4.3.3}$$

Os resultados obtidos foram SE=84% e SP=89%.

4.4. Algoritmo de Hadjileontiadis e Rekanos

Dada a grande quantidade de dados que é necessário processar em estudos como o que se pretende realizar (vide Capítulo 3), a rapidez de processamento constitui um requisito importante de um algoritmo automático de detecção de crepitações. Na revisão de literatura, o algoritmo *Fractal Dimension* (FD) apresentado por Hadjileontiadis e Rekanos [2], destaca-se desse ponto de vista, para além do bom desempenho reclamado pelos autores.

4.4.1. Esquema Global

A Figura 4.7 apresenta o diagrama de blocos deste algoritmo:

- No primeiro bloco é estimada a FD do som respiratório pela aplicação do algoritmo de Katz [55].
- O segundo bloco é um identificador de picos automáticos na FD (*FD-peak peeling algorithm*, FD-PPA) do som respiratório. Através da identificação dos picos obtém-se a localização e a duração das crepitações. A sensibilidade do identificador é controlada por um parâmetro ajustado empiricamente (que afecta o primeiro bloco) de modo a obter a máxima eficiência e desempenho do algoritmo. Os autores utilizaram o valor 0.006.
- No terceiro bloco são identificadas as crepitações pelos intervalos de FDPP acima do limiar 1.

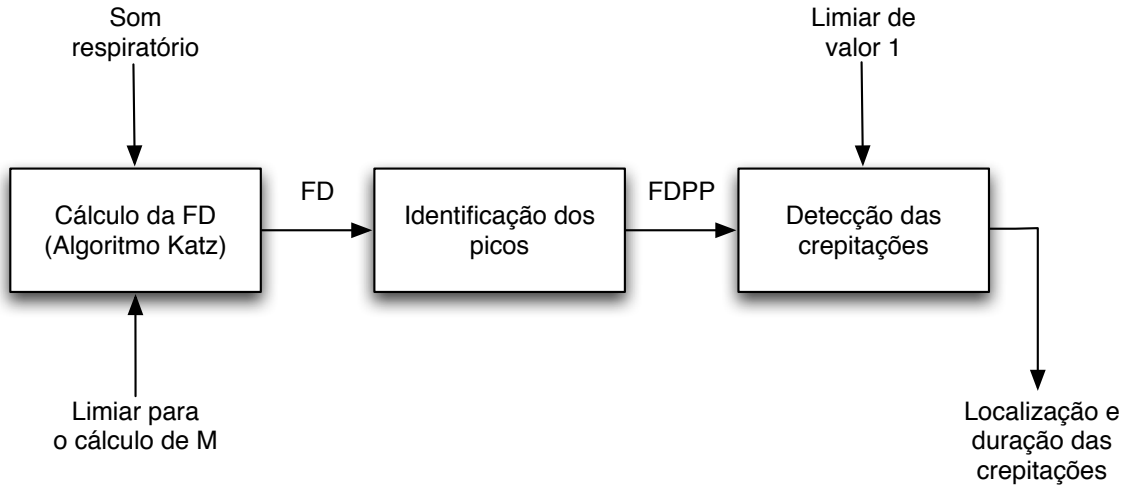


Figura 4.7 – Diagrama de blocos do algoritmo *Fractal Dimension (FD)*

Segue-se uma explicação mais pormenorizada do funcionamento de cada bloco.

4.4.2. Cálculo da FD

Para o cálculo da FD do som respiratório começa-se por definir uma janela de $M = \text{int}(0.006fs)$ amostras, onde $\text{int}(\cdot)$ representa a parte inteira do argumento e fs é a frequência de amostragem utilizada na aquisição dos sons respiratórios. O valor 0.006 é a constante estabelecida empiricamente já anteriormente mencionada. O autor observou que com a diminuição de M o valor de SE aumenta. De seguida, a janela com M amostras percorre o som respiratório de N amostras com 99% de sobreposição. Para cada posição da janela, é calculado um valor de FD atribuído ao ponto médio da janela.

O cálculo FD foi realizado pelo algoritmo de Katz [55], na qual a FD de uma curva definida por uma sequência de amostras é estimada por

$$D_s = \frac{\log_{10}(L)}{\log_{10}\left(\frac{d}{L}\right) + \log_{10}(n)} \quad \text{Equação 4.4.1}$$

onde L é o comprimento da curva, expresso pela soma das distâncias Euclidianas, $\text{dist}(i,j)$, entre sucessivos pontos:

$$L = \sum_{i=1}^{N-1} \text{dist}(i, i+1) \quad \text{Equação 4.4.2}$$

Ainda na Equação 4.4.1, d é o diâmetro da curva, dado por:

$$d = \max[\text{dist}(i, j)]; \quad i \neq j; \quad i, j \in [1, N] \quad \text{Equação 4.4.3}$$

Todavia, em curvas em que não há cruzamentos, o diâmetro d pode ser estimado pela distância entre a primeira amostra e a amostra mais distante na sequência:

$$d = \max[\text{dist}(1, j)]; \quad j \in [2, N] \quad \text{Equação 4.4.4}$$

Finalmente, n é o número de intervalos na curva, definido por:

$$n = \frac{L}{\bar{a}} \quad \text{Equação 4.4.5}$$

onde \bar{a} é a distância média entre pontos sucessivos:

$$\bar{a} = \frac{\sum_{i=1}^{N-1} \text{dist}(i, i+1)}{N-1} \quad \text{Equação 4.4.6}$$

Portanto,

$$n = N - 1 \quad \text{Equação 4.4.7}$$

O cálculo fica completo quando a janela acaba de percorrer todo o som respiratório. A Figura 4.8 apresenta um exemplo de FD estimada desta forma.




Figura 4.8 –Som respiratório e correspondente FD [2]

4.4.3. Identificação Automática dos Picos na FD

A FD do som assim calculada é então submetida a um algoritmo automático de detecção de picos (FD-PPA), com o intuito de identificar a localização e duração das crepitações.

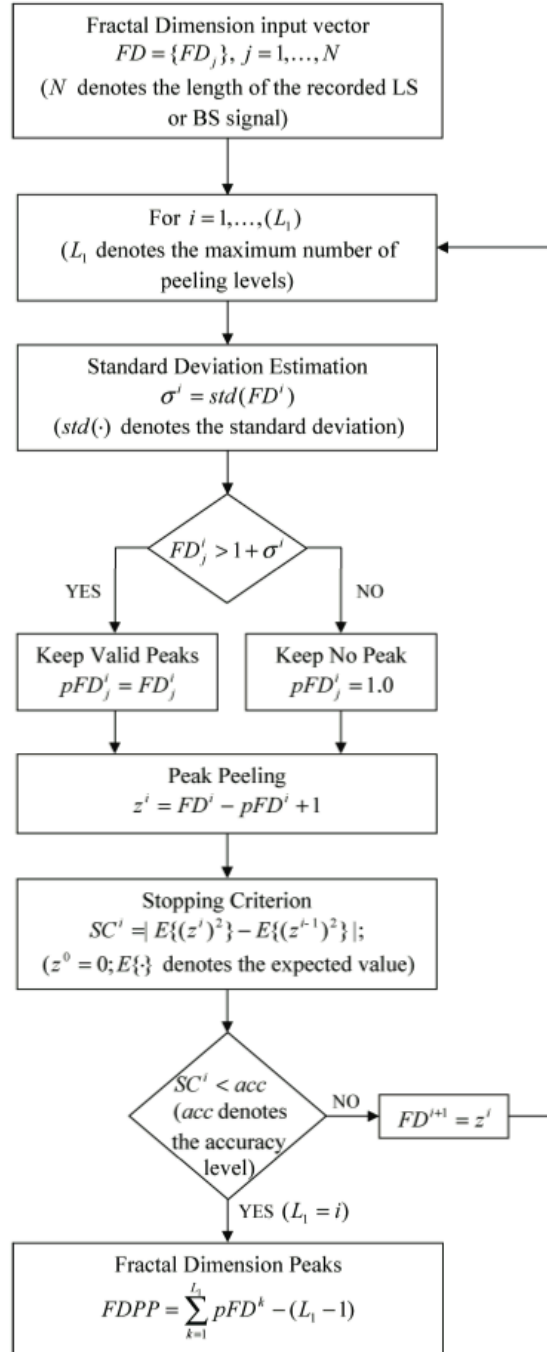


Figura 4.9 – Fluxograma do Algoritmo de Detecção de Picos na FD (FD-PPA) [54]

Trata-se, como mostra a Figura 4.9, de um procedimento iterativo auto-ajustável que encontra gradualmente as componentes do sinal responsáveis pelos picos. Deste modo, mesmo os picos FD de pequena amplitude, mas importantes, são identificados com precisão [54].

O sinal FDPP resultante da aplicação do algoritmo é igual a 1 excepto nos locais onde se encontram os picos. Utilizando um limiar de valor 1 facilmente se obtêm a localização e duração das crepitações. Em algumas situações, as crepitações identificadas apresentam duração anormalmente elevada, que indicia a existência de várias crepitações próximas não correctamente separadas. Estes casos aconselham reaplicação do algoritmo localmente. Com uma ou duas passagens do FD-PPA, a duração e localização de todas as crepitações são automaticamente identificadas. A Figura 4.10 ilustra o resultado da aplicação deste algoritmo.




Figura 4.10 –Som respiratório e correspondente FD e resultado final após a aplicação do algoritmo FD-PPA (FDPP=p) [2]

4.4.4. Validação

Os autores obtiveram sempre um desempenho de 100% nos seus resultados. Também afirmaram que este algoritmo é praticamente imune ao ruído.

4.5. Algoritmo de Bahoura e Lu

O algoritmo de Bahoura e Lu [4] é relativamente recente e bastante completo. Os autores reclamam um desempenho elevado. Pode ajudar a esclarecer se a separação do som respiratório nas suas partes estacionária e não estacionária é benéfica para a detecção de crepitações; a separação proposta baseia-se na transformada de wavelet por pacotes (*packet wavelet*), que é mais rápida que a transformada por *wavelets* adoptada pela maioria dos autores.

4.5.1. Esquema Global

A Figura 4.11 é o esquema completo do algoritmo proposto. Encontram-se dois blocos principais bem definidos:

- *Separação de crepitações*, baseada num filtro *wavelet packet transform-based stationary-non-stationary* (WPST-NST), responsável pela separação do som respiratório nas suas partes estacionária e não estacionária.
- *Identificação de crepitações*, subdividida em:
 - Filtro para remoção do ruído;
 - Detecção de crepitações por aplicação de um algoritmo de fractal dimension (FD) e de um detector de picos de crepitações (*crackle peak detector – CPD*);
 - Classificação de crepitações.

A implementação de cada subdivisão encontra-se descrita nas próximas secções.

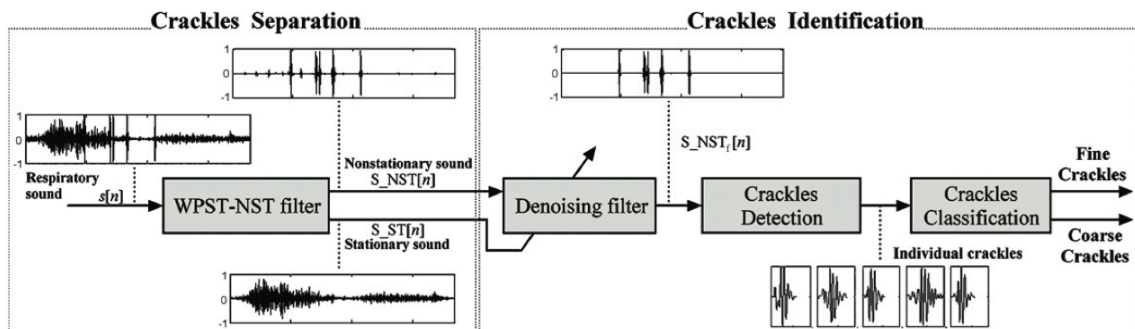


Figura 4.11 – Algoritmo proposto por Bahoura e Lu [4]

4.5.2. Parâmetros de Entrada

São utilizados ficheiros respiratórios provenientes dos mesmos repositórios usados em [4].

Os parâmetros usados no algoritmo são:

- $P_1=0,75$ e $P_2=2$ no filtro WPST-NST;
- $P=0.8$ no filtro de remoção de ruído;
- $\varepsilon=0.01$ no algoritmo de FD.

4.5.3. Filtro WPST-NST

A representação do esquema do filtro WPST-NST encontra-se na Figura 4.12 .

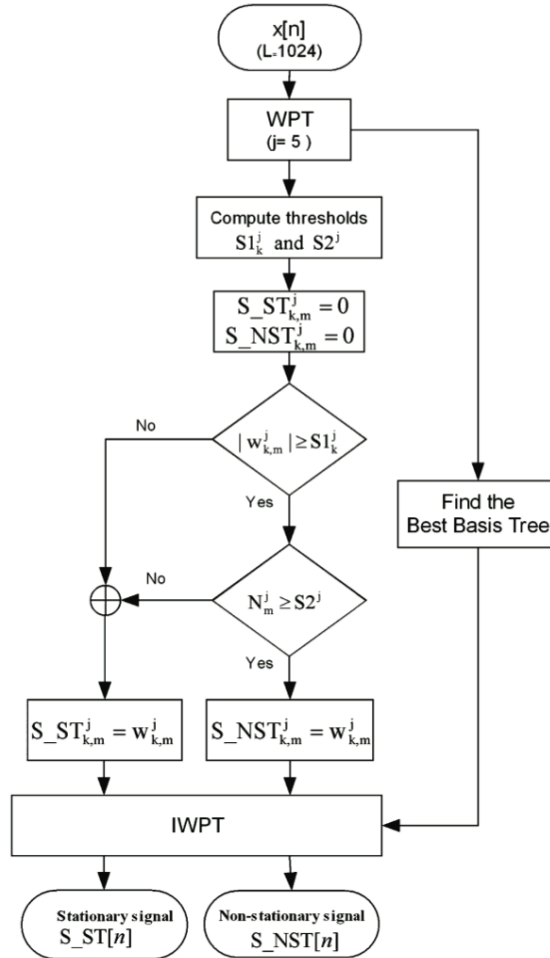


Figura 4.12 – Esquema da técnica de filtragem WPST-NST [4]

O filtro pode ser descrito nos seguintes passos:

- (1) O som respiratório $x[n]$ é dividido em segmentos de 1024 amostras com 75% de sobreposição.
- (2) Em cada segmento é utilizada a WPT. A WPT é aplicada até ao nível 5 usando como *mother wavelet* a *Daubechies-8*.

- (3) São marcados os coeficientes $w_k^j[m]$ com amplitude superior ao valor de *threshold* $S1^j$, definido por:

$$S1_k^j = P_1 \sigma_k^j \quad \text{Equação 4.5.1}$$

onde σ_k^j é o desvio padrão dos coeficientes da wavelet correspondentes à sub-banda de ordem k do nível j . O valor de P_1 é estabelecido empiricamente.

Portanto, o marcador $M_k^j[m]$ de um coeficiente $w_k^j[m]$ é definido por

$$M_k^j[m] = \begin{cases} 1 & \text{if } |w_k^j[m]| \geq S1_k^j \\ 0 & \text{if } else \end{cases} \quad \text{Equação 4.5.2}$$

- (4) Quantificação do número de marcadores relacionados com cada coeficiente $w_k^j[m]$ para todas as sub-bandas k do nível j :

$$N^j[m] = \sum_{k=1}^{2^j} M_k^j[m] \quad \text{Equação 4.5.3}$$

Definição de um segundo *threshold* $S2_k^j$ relacionado com a média dos números dos marcadores do nível j :

$$S2^j = P_2 \cdot \frac{1}{\frac{L}{2^j}} \sum_{m=1}^{L/2^j} N^j[m] \quad \text{Equação 4.5.4}$$

O coeficiente P_2 é fixado empiricamente.

- (5) Separação dos coeficientes $w_k^j[m]$ em duas classes: estacionários $S_ST_k^j[m]$ e não-estacionários $S_NST_k^j[m]$ de acordo com os valores de *threshold* $S1_k^j$ e $S2_k^j$.

Inicialização: $S_NST_k^j[m] := 0$; $S_ST_k^j[m] := 0$

if $|w_k^j[m]| \geq S1_k^j$ e $N^j[m] \geq S2^j$, then

$$S_NST_k^j[m] = w_k^j[m]$$

else

$$S_NST_k^j[m] = w_k^j[m]$$

$$\quad \text{Equação 4.5.5}$$

- (6) Escolha da melhor árvore da transformada de *wavelets* por pacotes, a partir dos coeficientes $w_k^j[m]$.
- (7) Divisão de cada segmento por um número de sobreposições. As partes estacionária e não-estacionária do som respiratório são obtidas através da aplicação da transformada inversa de *wavelets* por pacotes (*inverse wavelet packet transform* – IWPT) dos correspondentes coeficientes $S_ST_k^j[m]$ e $S_NST_k^j[m]$.

4.5.4. Filtro de remoção de ruído

Este filtro é aplicado para a remoção do ruído residual na parte do som respiratório onde se encontram as crepitações, ou seja, na componente não-estacionária previamente obtida. O filtro justifica-se por, geralmente, as crepitações possuírem alta energia comparativamente com a parte estacionária do som respiratório $S_ST[n]$. Se a parte não-estacionária do som respiratório $S_NST[n]$ for mais fraca durante algum período de tempo que a parte estacionária do som respiratório $S_ST[n]$, considera-se que não existem crepitações nesse intervalo. A acção deste filtro remove a maior parte do ruído presente na parte não-estacionária do som respiratório o que possibilita melhorar significativamente a credibilidade dos resultados das detecções. Os detalhes da implementação deste filtro são descritos nos seguintes passos:

- (1) Gera-se um conjunto vazio A e outro conjunto $\{1,2,...,N\}$ para anotar os índices, onde N é o comprimento do sinal de entrada (som respiratório). Inicialmente, $S_NST_t[n] = S_ST[n]$.

- (2) É aplicada uma janela simultaneamente à parte estacionária $S_ST[n]$ e à não estacionária $S_NST[n]$ do som respiratório, com uma sobreposição de 75%.

O tamanho da janela deve ser aproximadamente igual a metade do tamanho de uma crepitação. Com uma frequência de amostragem de 5kHz, foi escolhido $L=32$.

- (3) Ciclo para cada janela $k=1,2,...,K$
 - i. Cálculo da soma do valor absoluto do som respiratório em cada janela (n representa o índice de uma amostra na janela):

$$A_{ST}[k] = \sum_{n=(k-1)(1-\alpha)L+1}^{n=(k-1)(1-\alpha)L+L} |S_ST[n]|$$

Equação 4.5.6

$$A_{NST}[k] = \sum_{n=(k-1)(1-\alpha)L+1}^{n=(k-1)(1-\alpha)L+L} |S_NST[n]|$$

- ii. Se $A_{NST}[k] > P \cdot A_{ST}[k]$, índice da amostra na janela é adicionado ao conjunto A , onde P é um valor estabelecido empiricamente:

$$A = A \cup \{(k-1)(1-\alpha)L+1, (k-1)(1-\alpha)L+2, \dots, (k-1)(1-\alpha)L+L\}$$

Equação 4.5.7

- (4) Finalmente, as amostras da parte não-estacionária do sinal são colocadas a zero caso não estejam incluídas no conjunto A :

$$S_{NST_f}(\overline{\Omega \cup A}) = 0$$

Equação 4.5.8

4.5.5. Detecção de Crepitações. Algoritmo FD

Neste algoritmo também se estima a FD do som respiratório, no entanto os autores não utilizaram o método de Katz [55] mas sim o método de Sevcik [3]. Neste método alternativo, as abcissas e as ordenadas são sujeitas a uma dupla transformação linear que as transforma numa unidade quadrática. Tal como no algoritmo anterior, uma janela vai percorrer o som respiratório, no entanto, neste caso a janela apenas percorre a parte não estacionária, com 99% de sobreposição. O ponto FD estimado é atribuído ao ponto médio da janela. Sevcik [3] usou a seguinte definição para o cálculo da FD de uma curva:

$$D_s = 1 + \frac{\ln(L)}{\ln[2.(N - 1)]}$$

Equação 4.5.9

onde L representa o comprimento total da curva, i.e. a soma das distâncias Euclidianas entre sucessivos pontos:

$$L = \sum_{i=1}^{N-1} \text{dist}(i, i + 1)$$

Equação 4.5.10

e N é o número de amostras da janela analisada, sendo N-1 o número de passos da forma de onda na janela.

4.5.6. Detecção dos Picos das Crepitações (CPD)

Na representação (Figura 4.13) da FD da parte não-estacionária do som respiratório, cada crepitação é caracterizada por um pico distinto. A posição da crepitação pode ser facilmente revelada através da localização desses picos. Os autores propuseram a implementação de um método estatístico que avalia a variação de uma curva FD.

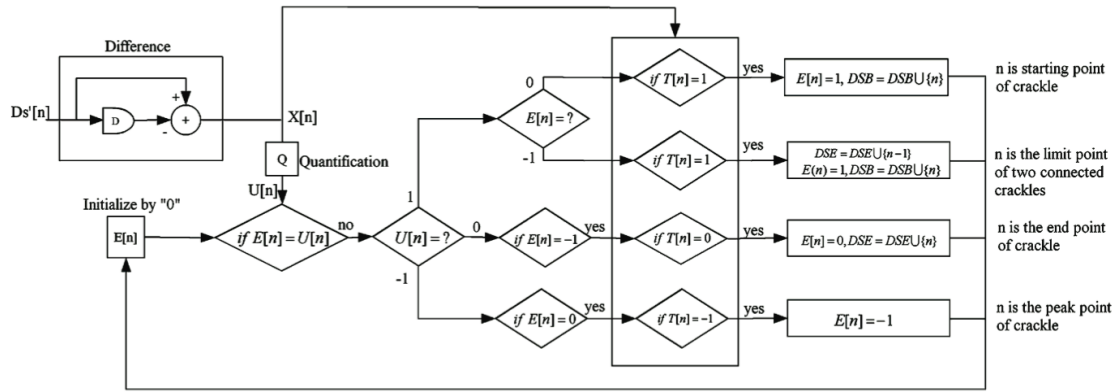


Figura 4.13 – Esquema do algoritmo de detecção de picos (CPD) [4]

A partir da Figura 4.13, descreve-se o algoritmo CPD passo a passo:

- (1) As pequenas ondulações na curva $D_S[n]$ são removidas por:

$$D'_S[n] = \begin{cases} D_S[n] - 1 - \epsilon & \text{if } D_S[n] > 1 + \epsilon \\ 0 & \text{if not} \end{cases} \quad \text{Equação 4.5.11}$$

onde ϵ é um número muito pequeno igual a 0.001. $D'_S[n]$ tem um valor mínimo igual a 0. As partes que não são iguais a zero são consideradas crepitações.

- (2) São definidos três estados para a curva $D'_S[n]$ pelos seguintes números: -1="descendente", 0="horizontal", 1="ascendente".
- (3) Cálculo da função diferencial $X[n]$ e a sua quantificação $U[n]$, onde os valores de $U[n]$ correspondem aos três estados mencionados em cima, que indicam o estado de transição da curva $D'_S[n]$ no momento n :

$$X[n] = D'_S[n] - D'_S[n-1]$$

$$U[n] = \begin{cases} 1 & X[n] > 0 \\ 0 & X[n] = 0 \\ -1 & X[n] < 0 \end{cases} \quad \text{Equação 4.5.12}$$

- (4) Definição da variável $E[n] \in [-1,0,1]$ que representa o estado global da curva D'_S no momento n , sendo inicializada com $E[0]=0$.
- (5) Definição da variável $T[n] \in [-1,0,1]$ que representa a tendência da curva D'_S no momento n :

$$U[n] = \begin{cases} -1 & \sum_{i=n+1}^{n+P} X[n] < 0 \\ 0 & \sum_{i=n+1}^{n+P} X[n] = 0 \\ 1 & \sum_{i=n+1}^{n+P} X[n] > 0 \end{cases} \quad \text{Equação 4.5.13}$$

onde $P = \frac{N}{2} + 1$, sendo N o comprimento da janela.

- (6) Dois conjuntos, DSB e DSE, inicialmente vazios, armazenam os índices das crepitações.

4.5.7. Classificação das Crepitações

A melhor classificação obtida pelos autores foi quando recorreram a parâmetros de caracterização relacionados com a forma de onda de uma crepitação e aos conteúdos espectrais do som respiratório. Estes parâmetros por sua vez foram introduzidos em modelos de misturas gaussianas. Os modelos de misturas gaussianas são *clusters* estatísticos muito utilizados no reconhecimento da voz. São, no entanto, modelos necessitam de efectuar uma aprendizagem.

4.5.8. Validação do Algoritmo

Na Tabela 4.3, observamos que a separação do som respiratório nas suas partes estacionária e não-estacionária por utilização do filtro WPST-NST consegue ter um desempenho elevado, semelhante ao registado pelo filtro WTST-NST; no entanto, é cinco vezes mais rápida.

Respiratory sounds	Real number of crackles (RN)	WPST-NST			WTST-NST		
		Correctly separated number (SN)	Separation rate SR_{WP} (%)	Required time RT_{WP} (s)	Correctly separated number (SN)	Separation rate SR_{WT} (%)	Required time RT_{WT} (s)
Fine crackles							
FC01	19	19	100	2.6	19	100	12.5
FC02	21	21	100	2.5	21	100	12.2
FC03	18	17	94.4	2.3	18	100	13.6
FC04	14	14	100	3.3	14	100	16.4
FC05	43	42	97.7	12.1	43	100	57.9
Coarse crackles							
CC01	23	23	100	6.6	22	95.7	31.3
CC02	20	19	95.0	5.4	19	95.0	26.4
CC03	9	9	100	5.3	9	100	25.8
CC04	8	8	100	4.3	8	100	21.7
CC05	7	7	100	1.7	7	100	8.2
Total	182	179	98.3	46.1	180	98.9	226

Tabela 4.3 – Desempenho dos filtros de separação WPST-NST e WT-ST [4]

Na Tabela 4.4 encontram-se os valores de desempenho da detecção de crepitações. Nos ficheiros analisados, os valores de sensibilidade e de precisão são,

respectivamente, 92.9% e 94.4% se for aplicado o filtro de WPST-NST e 94.4% e 63.4% se for aplicado o filtro de WTST-NST. Portanto, o melhor desempenho é conseguido com o filtro WPST-NST.

Respiratory sounds	Real number of crackles	WPST-NST			WTST-NST		
		TP	FP	FN	TP	FP	FN
Fine crackles							
FC01	19	18	1	1	18	2	1
FC02	21	20	0	1	21	2	0
FC03	18	17	0	1	17	6	1
FC04	14	14	0	0	14	2	0
FC05	43	39	0	4	42	9	1
Coarse crackles							
CC01	23	22	1	1	22	6	1
CC02	20	17	2	3	18	5	2
CC03	9	8	0	1	9	5	0
CC04	8	8	0	0	8	2	0
CC05	7	6	1	1	5	3	2
Normal sounds							
NS01	0	0	1	0	0	10	0
NS02	0	0	0	0	0	6	0
NS03	0	0	1	0	0	12	0
NS04	0	0	2	0	0	10	0
Wheezing							
WS01	0	0	0	0	0	10	0
WS02	0	0	1	0	0	4	0
WS03	0	0	0	0	0	5	0
WS04	0	0	0	0	0	2	0
Total	182	169	10	13	174	101	8
Sensitivity (%)		92.9			95.6		
Positive predictivity (%)		94.4			63.3		

Tabela 4.4 – Desempenho da detecção de crepitações com o algoritmo de Bahoura e Lu [4]

5. Implementação e Avaliação de Detectores de Crepitações

Este capítulo descreve a implementação de um conjunto seleccionado de algoritmos de detecção. O código *MatLab* desenvolvido para o efeito encontra-se documentado em detalhe no Anexo C, no Anexo D, no Anexo E e no Anexo F. Foi conveniente definir, para cada um dos algoritmos, a gama útil de limiares a considerar nos testes de avaliação de desempenho. A execução desses testes foi sistematizada com o auxílio de uma interface gráfica construída igualmente em *MatLab* e descrita no Anexo A.

5.1. Algoritmo de Vannuccini et al.



5.1.1. Versão Original

A implementação do algoritmo de Vannuccini et al. em *MatLab* (vide Anexo C) segue os passos descritos na secção 4.3. Os sons do repositório utilizado, originalmente amostrados a 44100 Hz, foram decimados para adoptar a frequência (8000Hz) e manter os parâmetros do filtro SG indicados no artigo - vide secção 4.3.3. A única operação não contemplada no artigo foi uma filtragem passa-alto com frequência de corte de 95Hz, para remoção de ruído provocado pelo coração e pelos músculos respiratórios.

Antes de realizar testes formais de avaliação de desempenho, considerou-se conveniente estabelecer empiricamente uma gama útil de variação do limiar T. Para tal, obtiveram-se as curvas de SE, PPV e F apresentadas na Figura 5.1, que contemplam uma gama bastante alargada de limiares e cinco ficheiros escolhidos aleatoriamente no repositório de teste, a saber:

- (1) Cr_LR1_1_processed
- (2) Cr_LR1_2_1_processed
- (3) Cr_LR1_2_2_processed
- (4) c_p1_b1_PL_processed
- (5) c_p6_b1_Pr_processed

Três destes ficheiros são de pacientes diagnosticados com Fibrose Quística e dois são de pacientes com Pneumonia. A presença de patologias diferentes submete os algoritmos de detecção a condições mais diversas, o que pareceu vantajoso para este efeito.






Figura 5.1 – Teste preliminar do algoritmo Vannuccini et al..

Tendo em conta este teste preliminar, adoptou-se a gama útil [1.5 3.75]. A Figura 5.2 resulta da execução do algoritmo com 10 limiares T regularmente espaçados nesta gama e com um T_w de 5ms (sugerido pelos autores). Mostra as curvas de SE, PPV e F obtidas para cada som, bem como as correspondentes médias em todo o repositório, calculadas como segue:

$$\begin{aligned}
 \langle SE \rangle &= \frac{\sum_{i=1}^{N_s} (SE_i)}{N_s} & \langle PPV \rangle &= \frac{\sum_{i=1}^{N_s} (PPV_i)}{N_s} & \langle F \rangle &= \frac{\sum_{i=1}^{N_s} (F_i)}{N_s} & \text{Equação 5.1.1} \\
 N_s &= \text{Número de sons} & N_s &= \text{Número de sons} & N_s &= \text{Número de sons}
 \end{aligned}$$

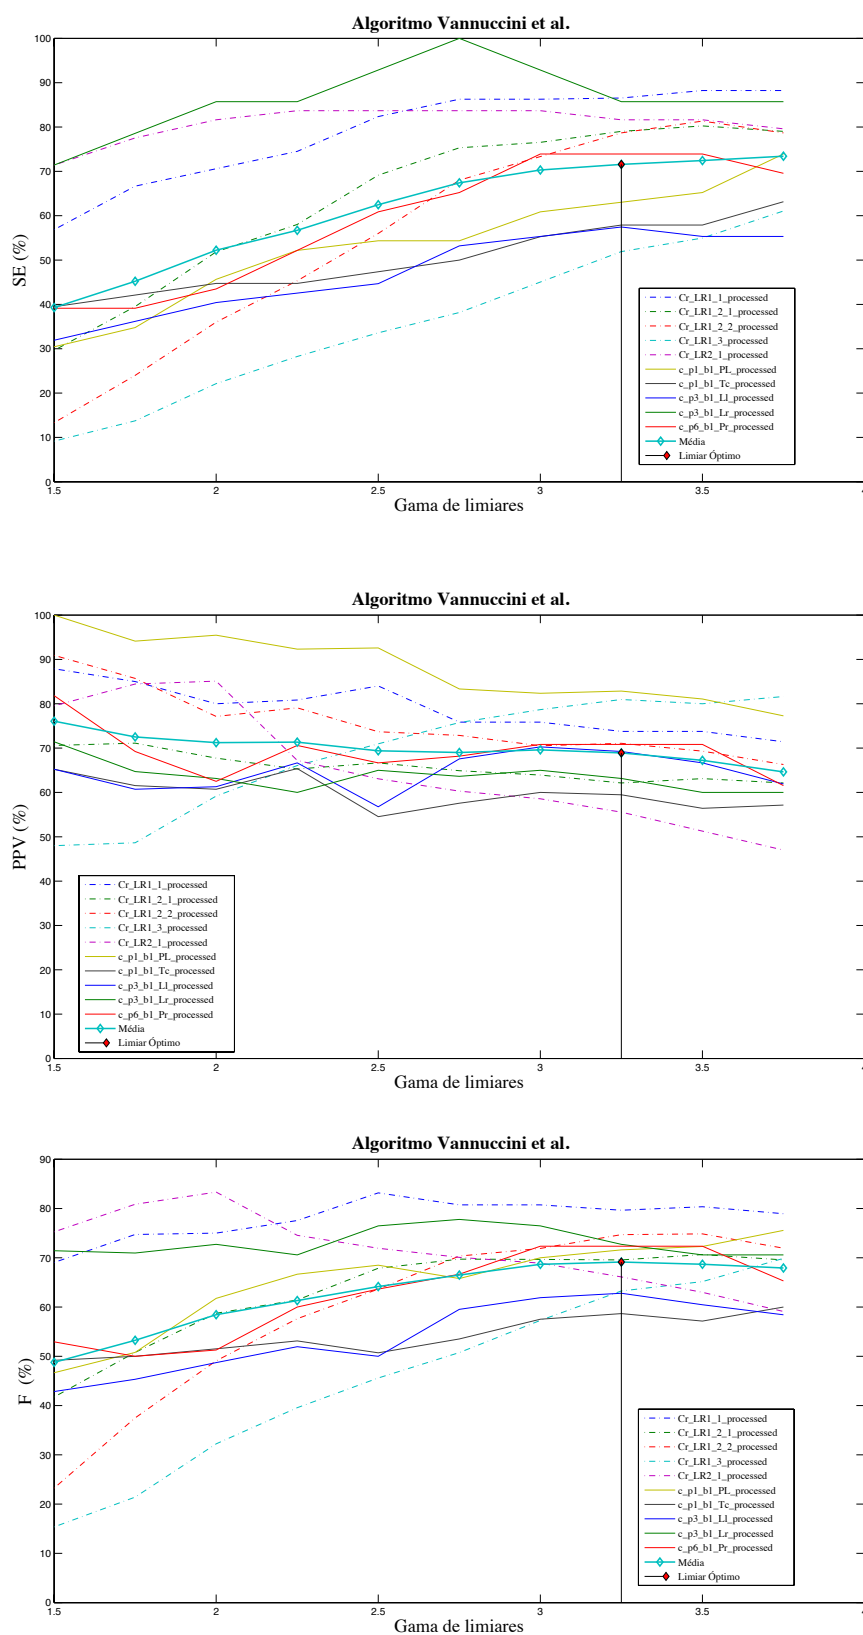


Figura 5.2 – Parâmetros SE, PPV e F do algoritmo de Vannuccini et al. no repositório de teste.

O limiar de máximo desempenho médio (i.e. de máximo $\langle F \rangle$), que designaremos *limiar óptimo*, é assinalado na figura e tem o valor $L_{opt}=3.25$. A Tabela 5.1 apresenta os correspondentes valores de SE, PPV e F obtidos para cada ficheiro. Os valores médios são, respectivamente, 71,6%, 68,9% e 69,1%.

Som Respiratório	Anotados	Limiar	Detectados	TP	FP	FN	SE(%)	PPV(%)	F(%)
Cr_LR1_1_processed	51	3.25	61	45	16	7	86.53	73.77	79.64
Cr_LR1_2_1_processed	81	3.25	103	64	39	17	79.01	62.13	69.56
Cr_LR1_2_2_processed	75	3.25	83	59	24	16	78.66	71.08	74.68
Cr_LR1_3_processed	131	3.25	84	68	16	63	51.90	80.95	63.25
Cr_LR2_1_processed	49	3.25	72	40	32	9	81.63	55.55	66.11
c_p1_b1_PL_processed	46	3.25	35	29	6	17	63.04	82.85	71.60
c_p1_b1_Tc_processed	38	3.25	37	22	15	16	57.89	59.45	58.66
c_p3_b1_LL_processed	47	3.25	39	27	12	20	57.44	69.23	62.79
c_p3_b1_Lr_processed	14	3.25	19	12	7	2	85.71	63.15	72.73
c_p6_b1_Pr_processed	23	3.25	24	17	7	6	73.9	70.83	72.34

Tabela 5.1 – Desempenho óptimo do algoritmo de Vannuccini et al..

Os limiares de máximo desempenho em cada som respiratório, como mostra a Tabela 5.2, não correspondem necessariamente ao limiar óptimo do conjunto.

Som Respiratório	Anotados	Limiar	Detectados	TP	FP	FN	SE (%)	PPV (%)	F (%)
Cr_LR1_1_processed	51	2.5	50	42	8	9	82.35	84	83.16
Cr_LR1_2_1_processed	81	3.5	103	65	38	16	80.24	63.10	70.65
Cr_LR1_2_2_processed	75	3.5	88	61	27	14	81.33	69.31	74.84
Cr_LR1_3_processed	131	3.75	98	80	18	51	61.06	81.63	69.86
Cr_LR2_1_processed	49	2	47	40	7	9	81.63	85.10	83.33
c_p1_b1_PL_processed	46	3.25	35	29	6	17	63.04	82.85	71.60
c_p1_b1_Tc_processed	38	3.75	42	24	18	14	63.15	57.14	60
c_p3_b1_LL_processed	47	3.25	39	27	12	20	57.44	69.23	62.79
c_p3_b1_Lr_processed	14	2.75	22	14	8	0	100	63.63	77.77
c_p6_b1_Pr_processed	23	3.25	24	17	7	6	73.91	70.83	72.34

Tabela 5.2 – Pontos de máximo desempenho do algoritmo de Vannuccini et al..


Os valores médios de SE, PPV e F nos pontos da Tabela 5.2 são respectivamente 74,4%, 72,7% e 72,6%. É interessante notar que este valor de F é 5% superior ao valor óptimo.

Os autores do método [1] reclamam um valor de sensibilidade de 84%. Apresentam também um parâmetro que designam *SP* (vide Equação 4.3.3) para o qual reclamam um valor de 89%. Os valores aqui obtidos no limiar óptimo para os mesmos parâmetros, são 14,8% e 27% inferiores, respectivamente.

5.1.2. Variante

Face aos resultados obtidos, procurou-se flexibilizar o algoritmo no sentido de aumentar os cenários de detecção de crepitações. Experimentou-se, para isso, a remoção das condições 2 e 3 descritas na secção 4.3, considerando-se assim que uma crepitação é detectada desde que estejam presentes pelo menos 3 picos no intervalo T_w (5ms).

Um teste preliminar em tudo semelhante ao anterior (análise empírica das curvas da Figura 5.3) conduziu à escolha da mesma gama útil: [1.5 3.75].







Figura 5.3 – Teste preliminar do algoritmo de Vannuccini et al. alterado .

Testes efectuados, tal como anteriormente, com 10 limiares regularmente espaçados nesta gama, permitiram obter as curvas de SE, PPV e F presentes na Figura 5.4.



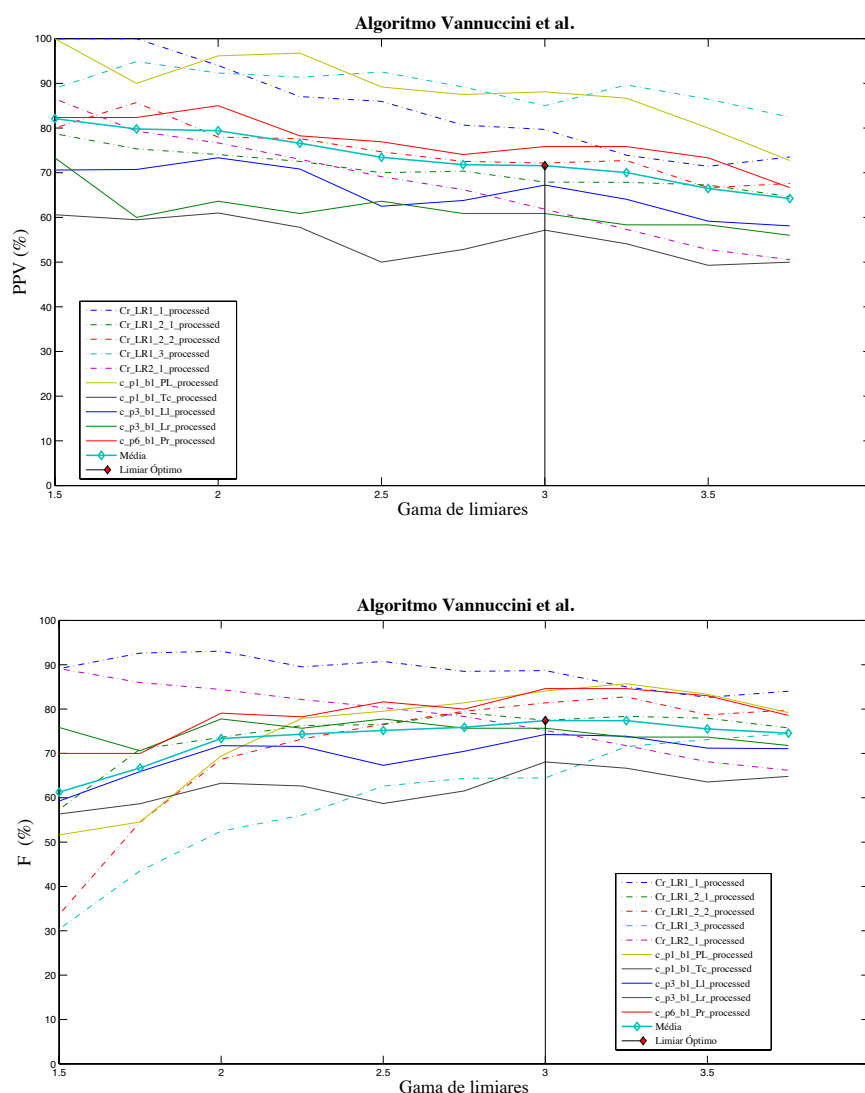


Figura 5.4. – Parâmetros SE, PPV e F do algoritmo de Vannuccini et al. alterado.

Na figura também se assinala o limiar ótimo, que é 3. Este limiar proporcionou, em média, SE=87,5%, PPV=71,6% e F=77,4% (dados da Tabela 5.3). Estas médias indicam uma clara melhoria de desempenho em relação à versão anterior, com um aumento de 12% em F, devido sobretudo ao aumento de SE em cerca de 22%.

Som Respiratório	Anotados	Limiar	Detectados	TP	FP	FN	SE(%)	PPV(%)	F(%)
Cr_LR1_1_processed	51	3	64	51	13	0	100	79.68	88.69
Cr_LR1_2_1_processed	81	3	109	74	35	8	90.24	67.88	77.48
Cr_LR1_2_2_processed	75	3	97	70	27	5	93.33	72.16	81.39
Cr_LR1_3_processed	131	3	80	68	12	63	51.90	85	64.4
Cr_LR2_1_processed	49	3	76	47	29	2	95.91	61.84	75.2
c_p1_b1_PL_processed	46	3	42	37	5	9	80.43	88.09	84.09
c_p1_b1_Tc_processed	38	3	56	32	24	6	84.21	57.14	68.08
c_p3_b1_Ll_processed	47	3	58	39	19	8	82.97	67.24	74.28
c_p3_b1_Lr_processed	14	3	23	14	9	0	100	60.86	75.67
c_p6_b1_Pr_processed	23	3	29	22	7	1	95.65	75.86	84.61

Tabela 5.3 – Desempenho óptimo do algoritmo de Vannuccini et al. alterado.

A Tabela 5.4 detalha a informação relativa aos pontos de máximo desempenho para cada som respiratório. Os valores médios de SE, PPV e F são, respectivamente, 88,2%, 75,5% e 80,5%. Também nesta nova implementação, o valor de F é aproximadamente 5% superior ao valor óptimo.

Som Respiratório	Anotados	Limiar	Detectados	TP	FP	FN	SE(%)	PPV(%)	F(%)
Cr_LR1_1_processed	51	2	50	47	3	4	92.15	94	93.06
Cr_LR1_2_1_processed	81	2.75	108	76	32	8	90.47	70.37	79.16
Cr_LR1_2_2_processed	75	3.25	99	72	27	3	96	72.72	82.75
Cr_LR1_3_processed	131	3.75	108	89	19	42	67.93	82.40	74.47
Cr_LR2_1_processed	49	1.5	52	45	7	4	91.83	86.53	89.10
c_p1_b1_PL_processed	46	3	42	37	5	9	80.43	88.09	84.09
c_p1_b1_Tc_processed	38	3	56	32	24	6	84.21	57.14	68.08
c_p3_b1_Ll_processed	47	3	58	39	19	8	82.97	67.24	74.28
c_p3_b1_Lr_processed	14	3	23	14	9	0	100	60.86	75.67
c_p6_b1_Pr_processed	23	3	29	22	7	1	95.65	75.86	84.61

Tabela 5.4 – Pontos de máximo desempenho do algoritmo de Vannuccini et al. alterado.


Comparativamente aos valores obtidos por Vannuccini et al., esta implementação apresenta um desempenho 4,2% superior em termos de SE mas 23,6% inferior em termos de SP.

5.2. Algoritmo *Fractal Dimension* (FD)

5.2.1. Método de Hadjileontiadis e Rekanos.

A implementação do algoritmo de Hadjileontiadis e Rekanos em *MatLab* (vide Anexo D) segue os passos descritos na secção 4.4. No detector de picos FD (*FD-peak peeling algorithm – FD-PPA*) proposto manifestou-se uma falha, que ocorria quando o algoritmo era re-aplicado para separação de picos, após, numa primeira passagem, ter assinalado zonas com mais de 20ms. Em alguns sons respiratórios, havia zonas em que o algoritmo era incapaz de realizar a separação, entrando em ciclo infinito. Para tornar o problema, teve-se em conta a indicação, fornecida pelos próprios autores, de que a ocorrência de intervalos com mais de 20 ms é rara e, que, com uma ou duas passagens pelo algoritmo de FD-PPA as crepitações são correctamente identificadas e detectadas. Assim, a passagem por FD-PPA foi limitada a duas iterações.

A Figura 5.5 apresenta as curvas de SE, PPV e F obtidas para estabelecer empiricamente uma gama útil para o limiar ajustável deste algoritmo. Escolheu-se o intervalo [0.012 0.03].






Figura 5.5 – Teste preliminar do algoritmo de Hadjileontiadis e Rekanos

A Figura 5.6 mostra as curvas de SE, PPV e F obtidas em cada som respiratório para 10 limiares uniformemente espaçados nesta gama útil, bem como as correspondentes médias em todo o repositório.

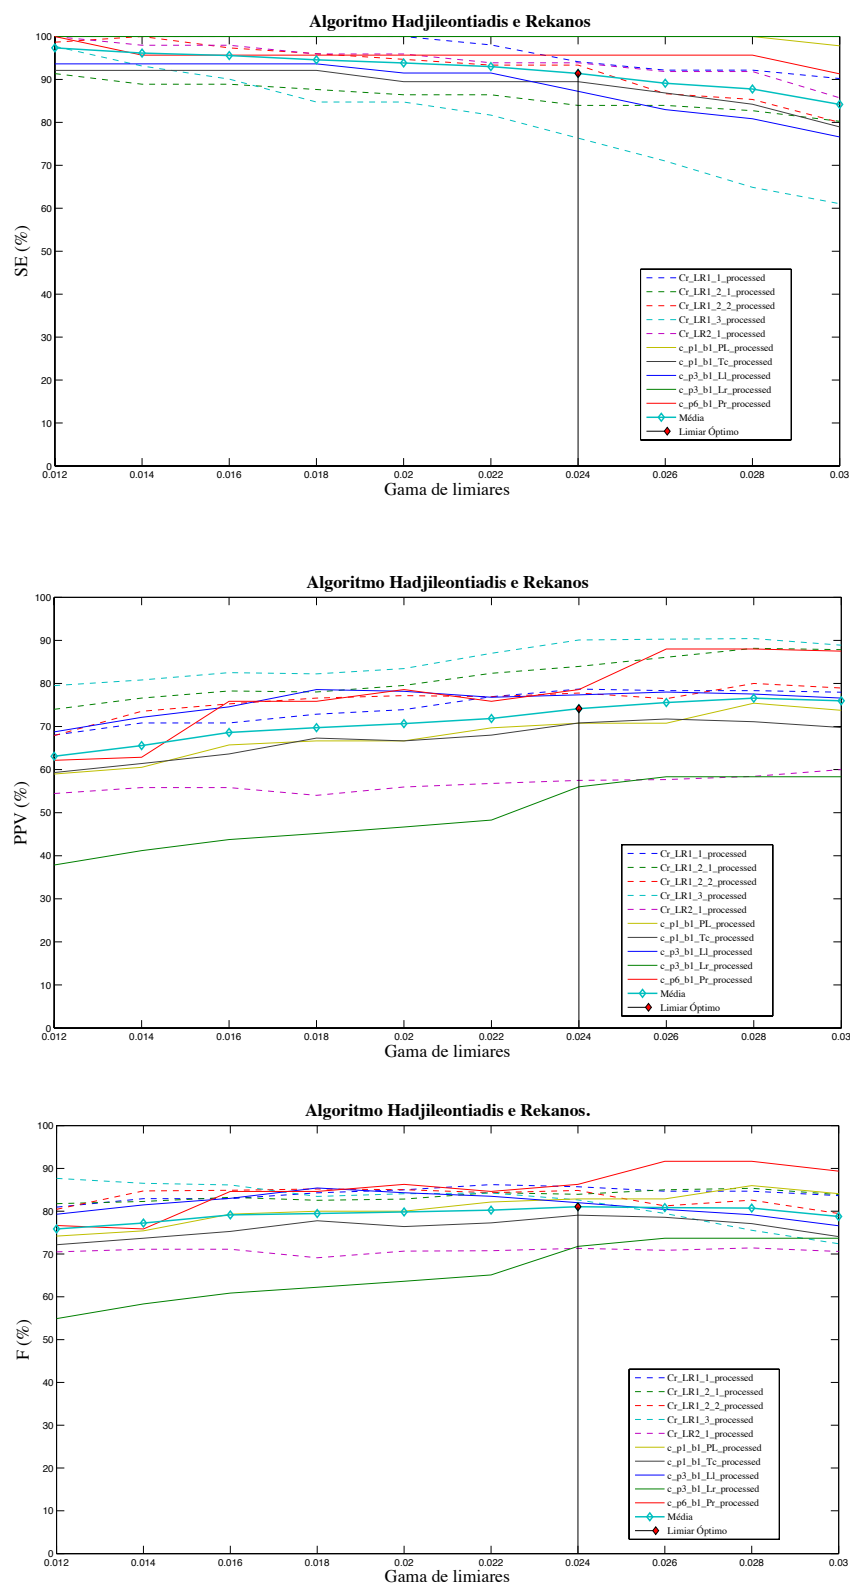


Figura 5.6 – Parâmetros SE, PPV e F do algoritmo de Hadj. e Rekanos no repositório de teste.

O limiar óptimo assinalado na figura tem o valor $L_{opt}=0.024$, a que correspondem, em média, $SE=91,4\%$, $PPV=74,5\%$ e $F=81\%$. A Tabela 5.5 apresenta os correspondentes valores de SE, PPV e F obtidos para cada ficheiro.

Som Respiratório	Anotados	Limiar	Detectados	TP	FP	FN	SE(%)	PPV(%)	F(%)
Cr_LR1_1_processed	51	0.024	61	48	13	3	94.11	78.68	85.71
Cr_LR1_2_1_processed	81	0.024	81	68	13	13	83.95	83.95	83.95
Cr_LR1_2_2_processed	75	0.024	90	70	20	5	93.33	77.77	84.84
Cr_LR1_3_processed	131	0.024	111	100	11	31	76.33	90.09	82.64
Cr_LR2_1_processed	49	0.024	80	46	34	3	93.87	57.5	71.31
c_p1_b1_PL_processed	46	0.024	65	46	19	0	100	70.76	82.88
c_p1_b1_Tc_processed	38	0.024	48	34	14	4	89.47	70.83	79.06
c_p3_b1_Ll_processed	47	0.024	53	41	12	6	87.23	77.35	82
c_p3_b1_Lr_processed	14	0.024	25	14	11	0	100	56	71.79
c_p6_b1_Pr_processed	23	0.024	28	22	6	1	95.65	78.57	86.27

Tabela 5.5 – Desempenho do algoritmo de Hadji. e Rekanos por aplicação do limiar óptimo.

Os pontos de máximo desempenho em cada som respiratório são enumerados na Tabela 5.6. Os valores médios de SE, PPV e F são respectivamente 94,6%, 74,6% e 82,6%.

Som Respiratório	Anotados	Limiar	Detectados	TP	FP	FN	SE(%)	PPV(%)	F(%)
Cr_LR1_1_processed	51	0.022	65	50	15	1	98.03	76.92	86.20
Cr_LR1_2_1_processed	81	0.028	76	67	9	14	82.71	88.15	85.35
Cr_LR1_2_2_processed	75	0.018	94	72	22	3	96	76.59	85.20
Cr_LR1_3_processed	131	0.012	161	128	33	3	97.71	79.50	87.67
Cr_LR2_1_processed	49	0.028	77	45	32	4	91.83	58.44	71.42
c_p1_b1_PL_processed	46	0.024	65	46	19	0	100	70.76	82.88
c_p1_b1_Tc_processed	38	0.024	48	34	14	4	89.47	70.83	79.06
c_p3_b1_Ll_processed	47	0.018	56	44	12	3	93.61	78.57	85.43
c_p3_b1_Lr_processed	14	0.026	24	14	10	0	100	58.33	73.68
c_p6_b1_Pr_processed	23	0.026	25	22	3	1	95.65	88	91.66

Tabela 5.6 – Pontos de máximo desempenho do algoritmo de Hadjileontiadis e Rekanos. .


Na comparação do desempenho deste algoritmo face ao anterior, é clara a sua vantagem, com F quase 5% superior (nos limiares óptimos). No entanto, o seu tempo médio de execução, avaliado em testes informais, é cerca de 6 vezes maior.

5.2.2. Versão de Sevcik

Apesar dos bons resultados obtidos com o algoritmo anterior, na revisão da literatura constata-se que vários autores identificaram uma falha no algoritmo de Katz utilizado por Hadjileontiadis e Rekanos para o cálculo da FD, especialmente sensível para sinais do tipo em análise [56, 62, 63]. Isto, aliado à dificuldade encontrada com o algoritmo FD-PPA, sugeriu o desenvolvimento de um novo algoritmo essencialmente com a mesma estrutura, mas substituindo o cálculo da FD pelo método de Katz por um outro, proposto por Sevcik [3] e descrito na secção 4.5.5, que a literatura indica ser mais rápido e com melhor desempenho.

A implementação está documentada em detalhe no Anexo E. O valor de N utilizado foi de 32. Para a identificação dos picos de FD, foi posto em prática um procedimento simples, que também envolve um limiar empírico, associado à amplitude da FD obtida. O algoritmo compara o sinal com o limiar, sendo registados os intervalos acima do limiar. Caso a duração dos intervalos registados seja superior a 5ms, considera-se que há uma crepitação.

A Figura 5.7 apresenta as curvas de SE, PPV e F obtidas para estabelecer empiricamente uma gama útil para o limiar ajustável deste algoritmo. Escolheu-se o intervalo [0.63 0.9].






Figura 5.7 – Teste preliminar do algoritmo FD de Sevcik.

Os testes realizaram-se com 10 limiares uniformemente espaçados na gama útil assim estabelecida. A Figura 5.8 mostra as resultantes curvas de SE, PPV e F.

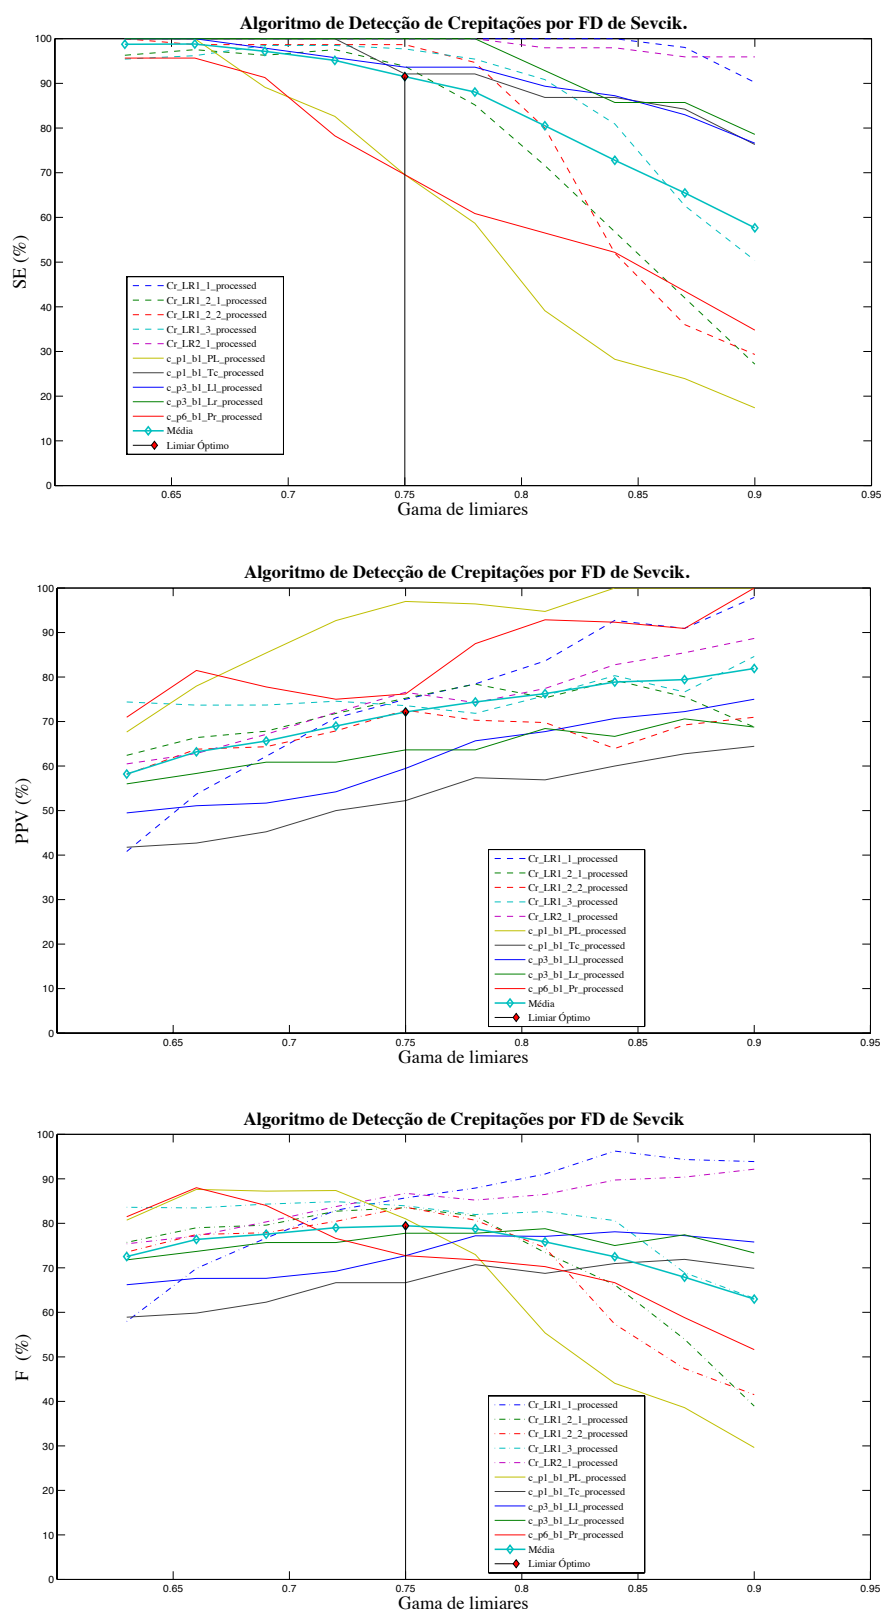


Figura 5.8 – Parâmetros SE, PPV e F do algoritmo FD de Sevcik no repositório de teste.

O limiar óptimo assinalado na figura tem o valor $L_{opt}=0.75$. A Tabela 5.7 apresenta os correspondentes valores de SE, PPV e F obtidos para cada ficheiro. Os valores médios são, respectivamente, 91,5%, 72,14% e 79,4%.

Som Respiratório	Anotados	Limiar	Detectados	TP	FP	FN	SE(%)	PPV(%)	F(%)
Cr_LR1_1_processed	51	0.75	68	51	17	0	100	75	85.71
Cr_LR1_2_1_processed	81	0.75	101	76	25	5	93.82	75.25	83.52
Cr_LR1_2_2_processed	75	0.75	102	74	28	1	98.67	72.55	83.62
Cr_LR1_3_processed	131	0.75	174	128	46	3	97.71	73.56	83.93
Cr_LR2_1_processed	49	0.75	64	49	15	0	100	76.56	86.73
c_p1_b1_PL_processed	46	0.75	33	32	1	14	69.57	96.97	81.01
c_p1_b1_Tc_processed	38	0.75	67	35	32	3	92.10	52.24	66.67
c_p3_b1_Ll_processed	47	0.75	74	44	30	3	93.62	59.46	72.73
c_p3_b1_Lr_processed	14	0.75	22	14	8	0	100	63.63	77.78
c_p6_b1_Pr_processed	23	0.75	21	16	5	7	69.56	76.19	72.73

Tabela 5.7- Desempenho do algoritmo de FD de Sevcik por aplicação do limiar óptimo.

Os resultados nos limiares de máximo desempenho podem ser observados na Tabela 5.8. Os valores médios de SE, PPV e F nos pontos da Tabela 5.8 são respectivamente 91,6%, 78,4% e 83,8%.

Som Respiratório	Anotados	Limiar	Detectados	TP	FP	FN	SE(%)	PPV(%)	F(%)
Cr_LR1_1_processed	51	0.84	55	51	4	0	100	92.73	96.23
Cr_LR1_2_1_processed	81	0.75	101	76	25	5	93.83	75.25	83.52
Cr_LR1_2_2_processed	75	0.75	102	74	28	1	98.67	72.55	83.62
Cr_LR1_3_processed	131	0.72	173	129	44	2	98.47	74.57	84.87
Cr_LR2_1_processed	49	0.9	53	47	6	2	95.92	88.68	92.16
c_p1_b1_PL_processed	46	0.75	33	32	1	14	69.57	96.97	81.01
c_p1_b1_Tc_processed	38	0.87	51	32	19	6	84.21	62.75	71.91
c_p3_b1_Ll_processed	47	0.84	58	41	17	6	87.23	70.69	78.10
c_p3_b1_Lr_processed	14	0.81	19	13	6	1	92.86	68.42	78.79
c_p6_b1_Pr_processed	23	0.66	27	22	5	1	95.65	81.48	88

Tabela 5.8 – Pontos de máximo desempenho do algoritmo FD de Sevcik .

5.3. Algoritmo de Bahoura e Lu

A implementação do algoritmo de Bahoura e Lu em *MatLab* (vide Anexo F) não segue integralmente na secção 4.5. Eis as alterações efectuadas:

- Aplicação de um algoritmo de detecção de picos de FD mais simples. Foi aplicado o detector da secção anterior, uma vez que é rápido e apresenta um bom desempenho.
- Recurso apenas a LDW para classificação das crepitações.
- Uso dos filtros WPST_NST como filtros de remoção de ruído e não de separação, como foi referido na secção 4.5.3.

Neste algoritmo os limiares utilizados na aplicação da WP possuem sempre os mesmos valores. A justificação desta decisão prende-se com o facto de as aproximações das decimações e das interpolações pela utilização da *wavelet Toolbox* do *MatLab*, levarem a que a separação da parte estacionária do sinal da parte não-estacionária por transformadas WP não seja tão rigorosa como o desejado. Deste modo, as transformadas WP foram apenas utilizadas para remoção do ruído, assumindo por isso sempre os mesmos valores de P_1 e P_2 . Nestas condições, o único limiar que varia no algoritmo está relacionado com a FD de Sevcik. Escolheu-se a mesma gama apresentada na secção anterior. Nos testes efectuados com este algoritmo, são assim utilizados 10 limiares uniformemente espaçados no intervalo [0.63 0.9].

A Figura 5.9 mostra as curvas de SE, PPV e F obtidas para cada som respiratório, bem como as correspondentes médias em todo o repositório.

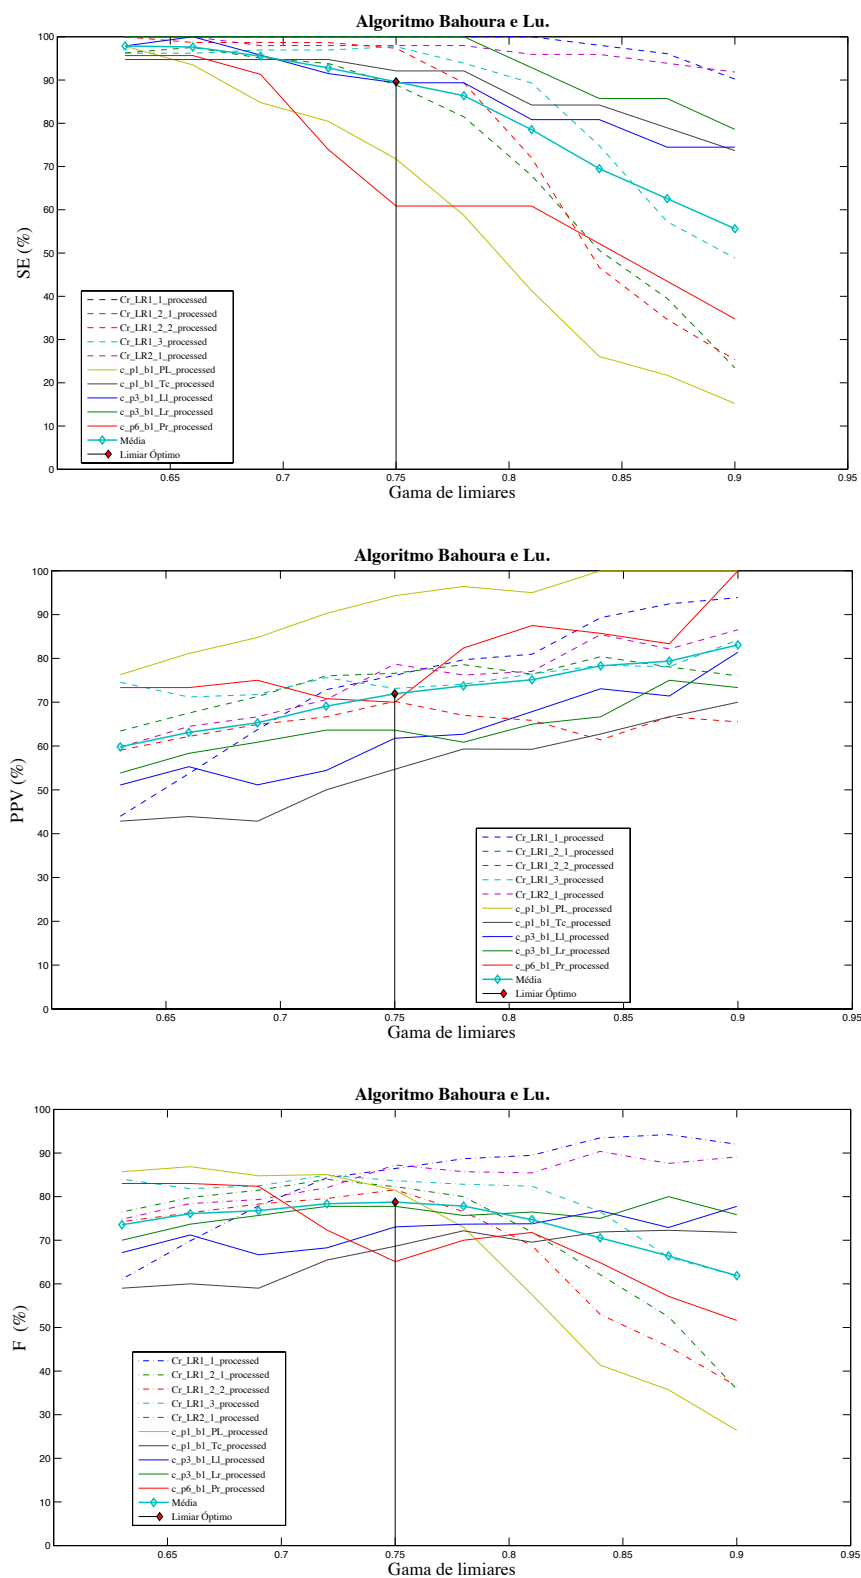


Figura 5.9 – Parâmetros SE, PPV e F do algoritmo de Bahoura e Lu no repositório de teste.

O limiar óptimo assinalado na figura tem o valor $L_{opt}=0.75$. A Tabela 5.9 apresenta os correspondentes valores de SE, PPV e F obtidos para cada ficheiro. Os valores médios são, respectivamente, 89,6%, 71,9% e 78,7%.

Som Respiratório	Anotados	Limiar	Detectados	TP	FP	FN	SE(%)	PPV(%)	F(%)
Cr_LR1_1_processed	51	0.75	67	51	16	0	100	76.12	86.44
Cr_LR1_2_1_processed	81	0.75	94	72	22	9	88.89	76.59	82.29
Cr_LR1_2_2_processed	75	0.75	104	73	31	2	97.33	70.19	81.56
Cr_LR1_3_processed	131	0.75	175	128	47	3	97.72	73.14	83.66
Cr_LR2_1_processed	49	0.75	61	48	13	1	97.96	78.69	87.27
c_p1_b1_PL_processed	46	0.75	35	33	2	13	71.74	94.29	81.48
c_p1_b1_Tc_processed	38	0.75	64	35	29	3	92.11	54.689	68.62
c_p3_b1_Ll_processed	47	0.75	68	42	26	5	89.36	61.76	73.04
c_p3_b1_Lr_processed	14	0.75	22	14	8	0	100	63.63	77.78
c_p6_b1_Pr_processed	23	0.75	20	14	6	9	60.87	70	65.12

Tabela 5.9 – Desempenho do algoritmo de Bahoura e Lu por aplicação do limiar óptimo.

Os pontos de máximo desempenho são enumerados na Tabela 5.10. Nela, os valores médios de SE, PPV e F são respectivamente 90,8%, 77,7% e 83,5%.

Som Respiratório	Anotados	Limiar	Detectados	TP	FP	FN	SE(%)	PPV(%)	F(%)
Cr_LR1_1_processed	51	0.87	53	49	4	2	96.10	92.45	94.23
Cr_LR1_2_1_processed	81	0.72	100	76	24	5	93.83	76	83.98
Cr_LR1_2_2_processed	75	0.75	104	73	31	2	97.33	70.19	81.56
Cr_LR1_3_processed	131	0.72	168	127	41	4	96.95	75.59	84.95
Cr_LR2_1_processed	49	0.84	55	47	8	2	95.92	85.45	90.38
c_p1_b1_PL_processed	46	0.66	53	43	10	3	93.48	81.13	86.87
c_p1_b1_Tc_processed	38	0.87	45	30	15	8	78.95	66.67	72.29
c_p3_b1_Ll_processed	47	0.9	43	35	8	12	74.47	81.39	77.78
c_p3_b1_Lr_processed	14	0.87	16	12	4	2	85.71	75	80
c_p6_b1_Pr_processed	23	0.63	30	22	8	1	95.65	73.33	83.01

Tabela 5.10 – Pontos de máximo desempenho do algoritmo de Bahoura e Lu.

Este algoritmo mostra-se apenas ligeiramente inferior ao anterior (menos de 1% em termos de F).

6. Desenvolvimento de Métodos Híbridos

O estudo detalhado e implementação de múltiplos algoritmos propostos na literatura (vide capítulos 4 e 5) sugeriu a possibilidade de os combinar total ou parcialmente no sentido de melhorar o desempenho na detecção de crepitações. São exploradas duas novas abordagens:

- SG-FD resultante da combinação de filtros SG com *fractal dimension*;
- Acordo entre algoritmos, que segue os mesmos princípios do acordo entre clínicos.

6.1. Híbrido SG-FD

Este algoritmo é a combinação de duas técnicas, nomeadamente os filtros SG que evidenciam as propriedades transitórias das crepitações através da primeira derivada do sinal, sobre a qual será aplicado o algoritmo FD de Sevcik (vide Anexo G).

O algoritmo foi implementado em *MatLab* por conjugação do trabalho realizado nas secções 4.3.3 e 5.2.2 (Anexo C e Anexo E). Para os testes de avaliação de desempenho, utilizaram-se 10 limiares uniformemente espaçados na gama útil [0,4 0,85] (obtida empiricamente pelo mesmo processo do Capítulo 5) . Obtiveram-se, como antes, as curvas de SE, PPV e F – vide Figura 6.1.

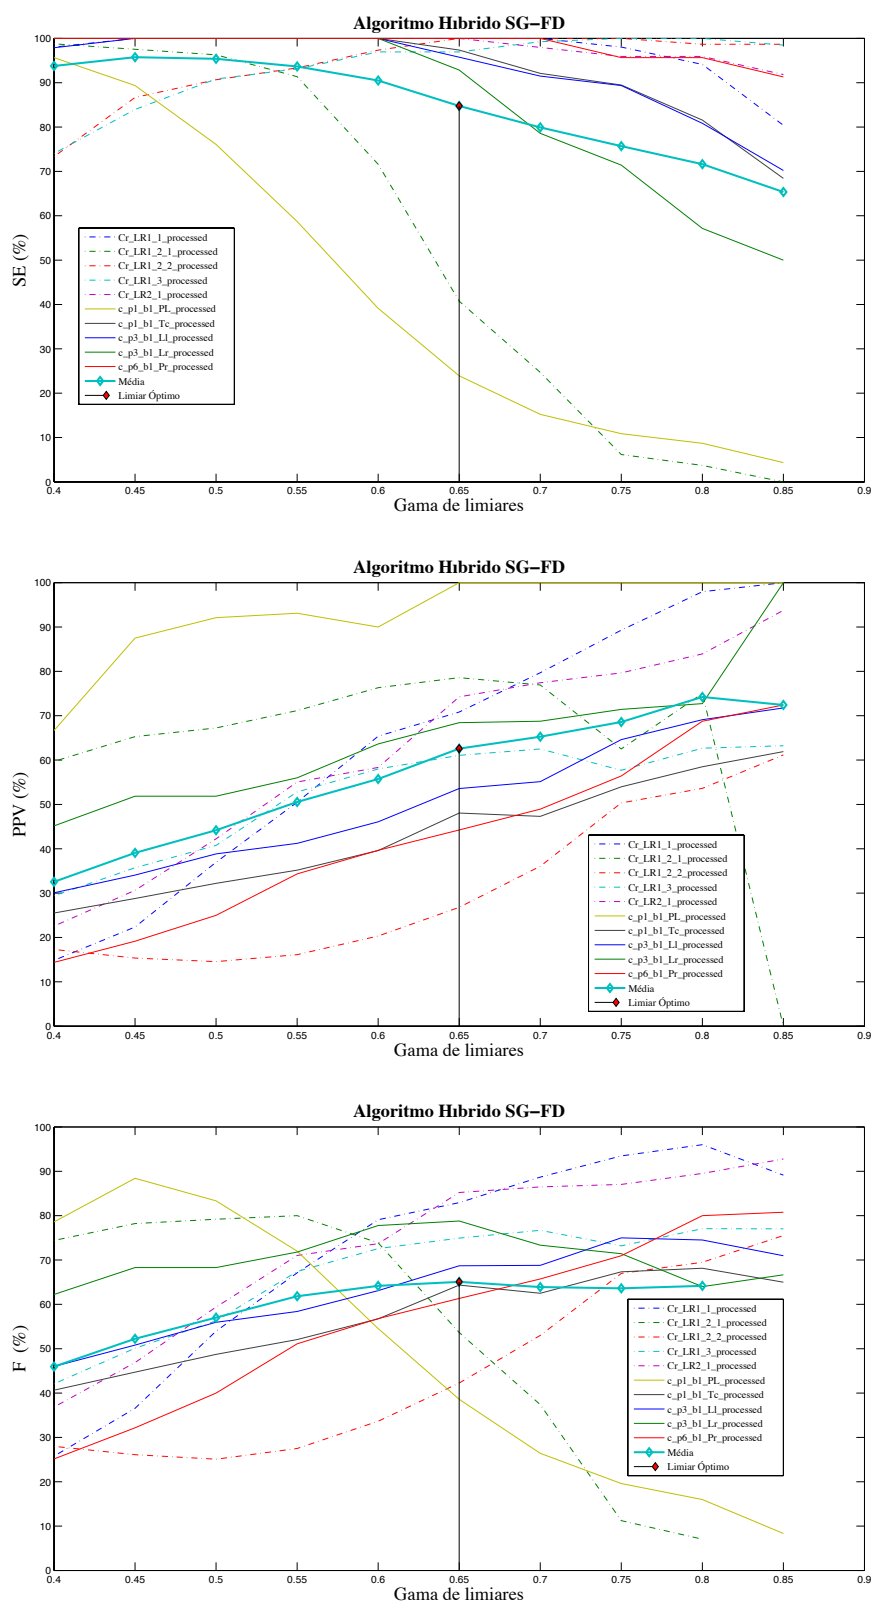


Figura 6.1 – Parâmetros SE, PPV e F do algoritmo SG-FD no repositório de teste.

Os valores médios de SE, PPV e parâmetro F, foram, respectivamente, de 84,75%, 62,57% e 65%. Estes resultados são claramente inferiores aos apresentados com os algoritmos do capítulo anterior, o que, aparentemente, invalida esta ideia.

6.2. Acordo entre Algoritmos

Esta outra ideia inspirou-se no método de acordo utilizado para estabelecimento de referências. Trata-se aqui de combinar ‘anotações’ feitas, não por profissionais de saúde, mas pelos algoritmos implementados no Capítulo 5. Estabeleceu-se uma anotação de acordo entre todos eles, por critérios idênticos aos do acordo gerado entre os profissionais de saúde (vide Capítulo 3).

6.2.1. Procedimento

A implementação e validação deste novo algoritmo obedeceram ao seguinte procedimento, cujos três primeiros passos foram já descritos no Capítulo 5:

- (1) Estimação empírica da gama útil de variação do limiar de cada algoritmo, como descreve o Capítulo 5. Foram definidos 10 limiares uniformemente espaçados dentro das gamas úteis estimadas:
 - a. Algoritmo de Vannuccini: [1.5:0.25:3.75]
 - b. Algoritmo de Hadjileontidis: [0.012:0.002:0.03]
 - c. Algoritmo de FD por Sevcik: [0.63:0.03:0.9]
 - d. Algoritmo de Bahoura e Lu: [0.63:0.03:0.9]
- (2) Obtenção das anotações de todos os sons do repositório de teste (10 ficheiros) usando todos os algoritmos seleccionados com todos os limiares escolhidos (total de $4 \times 10 \times 10 = 400$ anotações).
- (3) Cálculo, face à anotação de referência, dos valores de sensibilidade (SE) e precisão (PPV) das anotações obtidas no passo (2) e, a partir deles, também de F.
- (4) Determinação, para cada algoritmo, do limiar de máximo desempenho (nomeadamente em termos do factor F) considerando a média de todos os ficheiros.
- (5) Obtenção das anotações de todos os sons do repositório de teste (10 ficheiros) por acordo entre todos os algoritmos usando todas as combinações possíveis de limiares (10^4 combinações). É assim gerado um total de 100000 (10×10^4) anotações por acordo entre algoritmos.
- (6) Repetição do passo (3), agora para as anotações obtidas no passo (5).
- (7) Determinação, para cada som respiratório, do melhor acordo, i.e. a combinação de limiares que apresenta os máximos indicadores de

desempenho (nomeadamente F) – isto resulta em 10 valores máximos, um por ficheiro de som respiratório.

- (8) Determinação do acordo *ótimo*, i.e. a combinação de limiares que constitui o melhor compromisso para todo o repositório, por apresentar o máximo desempenho (nomeadamente em termos de F) considerando a média de todos os ficheiros.

6.2.2. Resultados

Para facilitar a visualização dos resultados em gráficos 3D, foram construídas 3 matrizes 100x100 contendo os valores médios de SE, PPV e F para todas as combinações possíveis dos limiares utilizados. No eixo *xx* foram representados os limiares dos dois primeiros algoritmos (Vannuccini et al. / Hadjileontiadis e Rekanos) e no eixo *yy*, os dos restantes (FD de Sevcik / Bahoura e Lu), como mostram a Figura 6.2. Como é visível, a sequência de valores foi organizada de modo a que entre elementos adjacentes das matrizes (nas direcções dos eixos) apenas variasse um limiar.

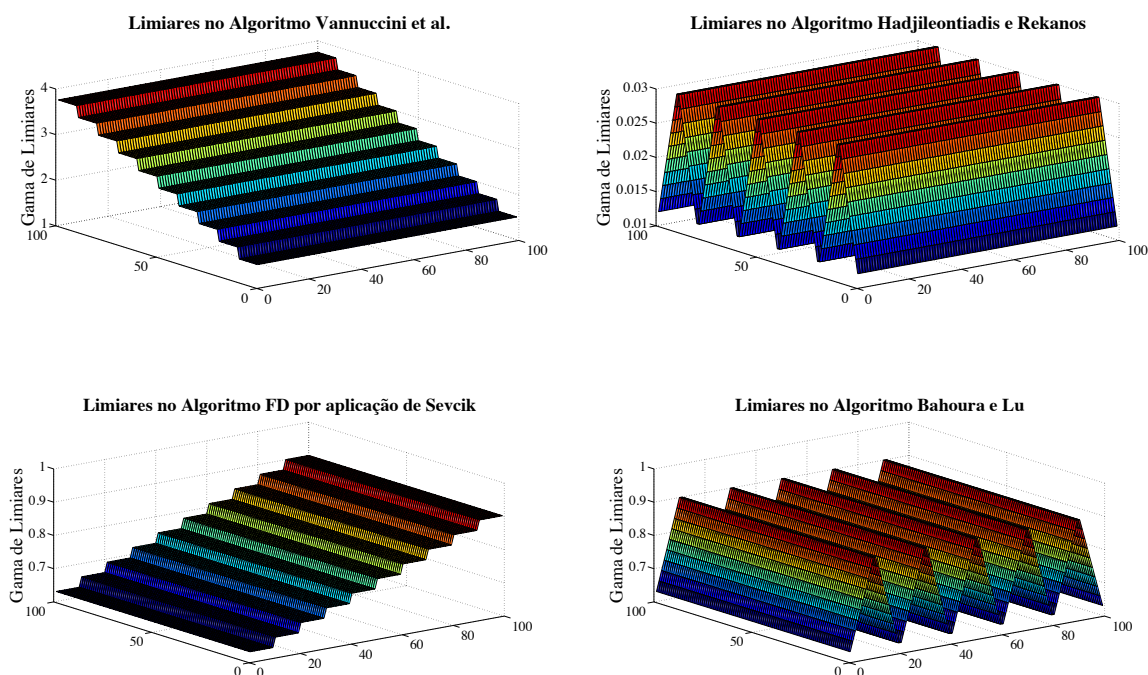


Figura 6.2 – Distribuição de limiares dos vários algoritmos utilizados nos gráficos da Figura 6.3, da Figura 6.4 e da Figura 6.5.

A aplicação do algoritmo proposto permitiu obter a curva do valor médio de SE, representada, na Figura 6.3, cujo máximo é de 91,4%.

Acordo de Algoritmos




Figura 6.3 – Curva do valor médio de SE obtida por acordo entre algoritmos

Obteve-se igualmente a curva do valor médio de PPV, representada na Figura 6.4 cujo o máximo é 83,67%.

Acordo de Algoritmos




Figura 6.4 – Curva do valor médio de PPV obtida por acordo entre algoritmos

Constata-se que quando o valor de SE é baixo, por o algoritmo detectar menos crepitações, o valor de PPV sobe, o que indica que o menor número de crepitações detectadas tendem a corresponder a verdadeiras crepitações (TP).

Foi também obtida a correspondente curva do valor médio de F, representada na Figura 6.5, cujo máximo é 86,72%.

Acordo de Algoritmos




Figura 6.5 – Curva do valor médio de F obtida por acordo entre algoritmos

Estes valores foram obtidos com o acordo entre algoritmos usando os limiares: 3,5 para o algoritmo Vannuccini et al., 0,024 para o algoritmo Hadjileontiadis e Rekanos, 0,84 para algoritmo FD de Sevcik e 0,66 para o algoritmo de Bahoura e Lu. O desempenho deste acordo em cada ficheiro encontra-se na Tabela 6.1.

Som Respiratório	Limiar Van	Limiar Hadji&Reno	Limiar Sev	Limiar Ba&Lu	Anot	Detec	TP	FP	FN	SE(%)	SP(%)	F(%)
Cr_LR1_1_processed	3.5	0.024	0.84	0.66	51	58	51	7	0	100	87.93	93.57
Cr_LR1_2_1_processed	3.5	0.024	0.84	0.66	81	83	71	12	10	87.65	85.54	86.58
Cr_LR1_2_2_processed	3.5	0.024	0.84	0.66	75	89	70	19	5	93.33	78.65	85.36
Cr_LR1_3_processed	3.5	0.024	0.84	0.66	131	107	102	5	29	77.86	95.32	85.71
Cr_LR2_1_processed	3.5	0.024	0.84	0.66	49	56	49	7	0	100	87.5	93.33
c_p1_b1_PL_processed	3.5	0.024	0.84	0.66	46	43	39	4	7	84.78	90.69	87.64
c_p1_b1_Tc_processed	3.5	0.024	0.84	0.66	38	51	34	17	4	89.47	66.66	76.40
c_p3_b1_Ul_processed	3.5	0.024	0.84	0.66	47	54	42	12	5	89.36	77.77	83.16
c_p3_b1_Lr_processed	3.5	0.024	0.84	0.66	14	21	14	7	0	100	66.66	80
c_p6_b1_Pr_processed	3.5	0.024	0.84	0.66	23	21	21	0	2	91.30	100	95.45
Média	-	-	-	-	-	-	-	-	-	91.40	83.67	86.72

Tabela 6.1 – Desempenho do acordo entre algoritmos por aplicação do conjunto de limiares que obtém o máximo valor médio de F.

Este desempenho óptimo em acordo pode comparar-se com os desempenhos óptimos individuais dos quatro algoritmos intervenientes, resumidos na Tabela 6.2.

Algoritmos	SE (%)	PPV (%)	F (%)
Algoritmo Vannuccini et al.	87,5	71,6	77,4
Algoritmo Hadjileontiadis e Rekanos	91,4	74,5	81
Algoritmo FD por Sevcik	91,5	72,1	79,4
Algoritmo Bahoura e Lu	89,6	71,9	78,7

Tabela 6.2 – Valores médios de SE, PPV e parâmetro F de cada algoritmo.

O valor de SE obtido pelo acordo de algoritmos (SE=91,4%) é semelhante ao obtido pelos melhores algoritmos executados individualmente. No entanto, o valor de PPV (83,67%) é cerca de 11% superior ao melhor valor registado por algoritmos executados individualmente. Isto resulta num valor de F (86,72%) 7% superior ao desse algoritmo (Hadjileontiadis e Rekanos).

Por curiosidade, verificaram-se os resultados do acordo usando os limiares óptimos de cada algoritmo (Tabela 6.3), com intuito de comparar com os valores do acordo óptimo.

Som Respiratório	Limiar Van	Limiar Hadji&Reno	Limiar Sev	Limiar Ba&Lu	Anot	Detec	TP	FP	FN	SE(%)	PPV(%)	F(%)
Cr_LR1_1_processed	3	0.024	0.75	0.75	51	62	51	11	0	100	82.25	90.26
Cr_LR1_2_1_processed	3	0.024	0.75	0.75	81	91	73	18	8	90.12	80.21	84.88
Cr_LR1_2_2_processed	3	0.024	0.75	0.75	75	95	74	21	1	98.66	77.89	87.05
Cr_LR1_3_processed	3	0.024	0.75	0.75	131	134	122	12	9	93.12	91.04	92.07
Cr_LR2_1_processed	3	0.024	0.75	0.75	49	57	48	9	1	97.95	84.21	90.56
c_p1_b1_PL_processed	3	0.024	0.75	0.75	46	34	33	1	13	71.73	97.05	82.5
c_p1_b1_Tc_processed	3	0.024	0.75	0.75	38	52	34	18	4	89.47	65.38	75.55
c_p3_b1_LI_processed	3	0.024	0.75	0.75	47	56	42	14	5	89.36	75	81.55
c_p3_b1_Lr_processed	3	0.024	0.75	0.75	14	19	14	5	0	100	73.68	84.85
c_p6_b1_Pr_processed	3	0.024	0.75	0.75	23	19	16	3	7	69.56	84.21	76.19
Média	-	-	-	-	-	-	-	-	-	89,99	81,09	84,54

Tabela 6.3 – Desempenho do acordo entre os limiares óptimos dos 4 algoritmos.

Os valores presentes na Tabela 6.3 mostram que o desempenho óptimo do acordo não é o desempenho do acordo entre óptimos, i.e. o algoritmo de acordo encontra uma combinação com melhor desempenho que a combinação dos limiares óptimos. Em termos de SE, a superioridade é apenas de 1,6%; o PPV é 3,2% superior. Consequentemente, o valor de F é 2,6% superior.

7. Conclusões e Trabalho Futuro

7.1. Conclusões

Pode considerar-se que os objectivos inicialmente propostos foram cumpridos. Implementou-se um conjunto de algoritmos de detecção automática de crepitações entre os mais relevantes encontrados na literatura, realizaram-se testes sistemáticos com o auxílio de uma interface construída em *MatLab* e investigaram-se (com sucesso) alternativas no sentido de aumentar o desempenho.

O desenvolvimento dos algoritmos propostos na literatura deparou com a dificuldade de replicar os testes originalmente efectuados pelos autores, por não serem públicos os repositórios e anotações de referência em que se baseiam.

Os testes realizados confirmaram o desempenho relativo dos vários métodos, mas produziram sistematicamente resultados inferiores aos reclamados pelos seus autores. Admite-se que esta diferença se deva às características do repositório aqui utilizado (ficheiros mais longos e incluindo outras patologias) e, sobretudo, à forma como foram obtidas anotações de referência (por acordo entre vários profissionais de saúde, ao invés de um único), que, em princípio, garante menor enviesamento. Foram definidos critérios de acordo adequados para construção dessas referências e construída uma aplicação para as obter de forma automática.

O algoritmo que apresentou pior desempenho foi o de Vannuccini et al. ($SE=71,6\%$, $PPV=68,9\%$ e $F=69,9\%$). Surpreendentemente, simplificando as condições propostas pelos autores, os resultados melhoraram sensivelmente ($SE=87,5\%$, $PPV=71,6\%$ e $F=77,4\%$), mantendo-se embora abaixo dos conseguidos com os restantes algoritmos replicados. O que obteve melhor desempenho foi o proposto por Hadjileontiadis e Rekanos ($SE=91,4\%$, $PPV=74,5\%$ e $F=81\%$). Constatou-se uma pequena falha no algoritmo de detecção de picos da função *fractal dimension* (FD). Para contorná-la, alterou-se o detector de picos FD para evitar ciclos infinitos.

Na implementação do algoritmo de Bahoura e Lu, fizeram-se várias modificações em relação ao sugerido pelos autores, devido sobretudo a dificuldades encontradas na separação do som respiratório por WP e filtros ST-NST, pelo que os resultados obtidos podem não ser representativos, ainda que se tenha atingido um desempenho comparável ao do obtido com o algoritmo de Hadjileontiadis e Rekanos (SE=89,6%, PPV=71,9% e F=78,7%).

Foram implementados dois novos algoritmos explorando a combinação dos métodos já implementados. O primeiro, uma combinação da filtragem SG (para obter a primeira derivada do sinal) com o algoritmo FD, obteve fracos resultados: SE=84,75% PPV=62,57% e F=65%.

Por fim, foi desenvolvido um método que resulta do acordo entre algoritmos. O desempenho deste método superou todos os anteriores, com um parâmetro F superior em 7% ao melhor desempenho registado pelo melhor algoritmo aplicado individualmente (Hadjileontiadis e Rekanos).

7.2. Trabalho Futuro

O estudo feito sobre sons pulmonares adventícios (em particular crepitações), o trabalho prático de implementação de algoritmos de detecção e os resultados obtidos nos testes de avaliação de desempenho sugerem numerosas possibilidades de trabalho futuro. Destacam-se as seguintes:

- Construir repositórios mais vastos e diversificados de sons respiratórios.
- Explorar novos critérios de acordo para a obtenção de anotações de referência (conduzindo a anotações de referência probabilísticas, por exemplo).
- Aperfeiçoar a aplicação desenvolvida para sistematizar o teste dos algoritmos e integrá-la com o *software* de anotação.
- Construir uma plataforma *Web*, aberta à comunidade científica e ao público interessado, para disponibilizar e desenvolver repositórios, ferramentas de anotação, critérios e métricas de acordo, anotações de referência e algoritmos de detecção.
- Re-verificar detalhadamente todo o código desenvolvido para implementação dos algoritmos de detecção e procurar validá-lo por comparação de resultados.
- Estudar em maior detalhe as técnicas de processamento de sinal envolvidas no algoritmo de Bahoura e Lu (em particular *wavelet packets* - WP), de modo a poder replicá-lo fielmente.
- Replicar outros algoritmos propostos recentemente na literatura (por

exemplo *Empirical Mode Decomposition* - EMD) e investigar o seu desempenho.

- Prosseguir testes de desempenho em repositórios mais vastos e face a referências obtidas com painéis de anotadores mais alargados, no sentido de tirar conclusões estatisticamente mais credíveis.
- Investigar em maior profundidade o acordo de algoritmos, procurando identificar o contributo de cada algoritmo para a melhoria de desempenho.
- Investigar de forma sistemática o peso computacional (tempo de execução) dos vários algoritmos.
- Implementar/desenvolver algoritmos de detecção de fases e ciclos respiratórios.
- Considerar a classificação de crepitações (inspiratórias/expiratórias, finas/grossas) na interface de anotação e implementar/desenvolver algoritmos de classificação.
- Aplicar/adaptar as técnicas desenvolvidas (acordo, sistematização dos testes de desempenho) a algoritmos de detecção de outros SPA, nomeadamente sibilâncias.

Anexo A – Interface Gráfica

A.1 Conteúdos

Este ponto contém a informação relativa à implementação em *MatLab* da interface gráfica, usada para sistematizar as anotações e testes de desempenho realizados neste trabalho (Capítulo 3, 5, 6). A lista de todos os *scripts* e ficheiros de dados utilizados é apresentada na tabela seguinte, em que se encontra também uma breve descrição de cada um.

Interface/	main.m	<i>Script</i> da primeira janela da interface que inicializa a interface e invoca todos os outros e onde são definidos parâmetros de entrada
	mainAcordo.m	<i>Script</i> da segunda janela da interface que inicializa a interface e invoca todos os outros e onde são definidos parâmetros de entrada
	Acordo	Anotações de referência resultantes do acordo entre profissionais de saúde; (por aplicação do algoritmo presente na pasta Anotações)
	AcordoThresh	Acordo entre algoritmos (resultados e <i>scripts</i>) (Os resultados não foram incluídos no CD por motivos de espaço)
	Algoritmos	Algoritmos Implementados (vide Anexo C, Anexo D, Anexo E, Anexo F).
	Anotacoes	Anotações dos profissionais de saúde; Algoritmo de acordo (vide Anexo B)
	Detect	Avaliação de desempenho dos algoritmos
	Ficheiros	Sons respiratórios
	Imagens	Imagens usadas na interface gráfica
	Thresh	Limiares máximos e limiar óptimo Inclui os scripts criados para a obtenção de ambos os limiares.
	ThreshRes	Pasta com o acordo entre os limiares de máximo e o acordo óptimo.

Tabela A.1 – *Scripts* e ficheiros de dados da Interface.

Estes conteúdos encontram-se na pasta ‘./Interface’ do CD de dados que integra esta dissertação (vide contracapa).

A.2 Apresentação

A interface gráfica foi desenvolvida em *MatLab* com a finalidade de facilitar o processamento sistemático de todos os algoritmos desenvolvidos.

Para utilizá-la introduz-se o comando ‘main’ na consola do *MatLab*, após o qual é possível observar a seguinte Figura A.1.

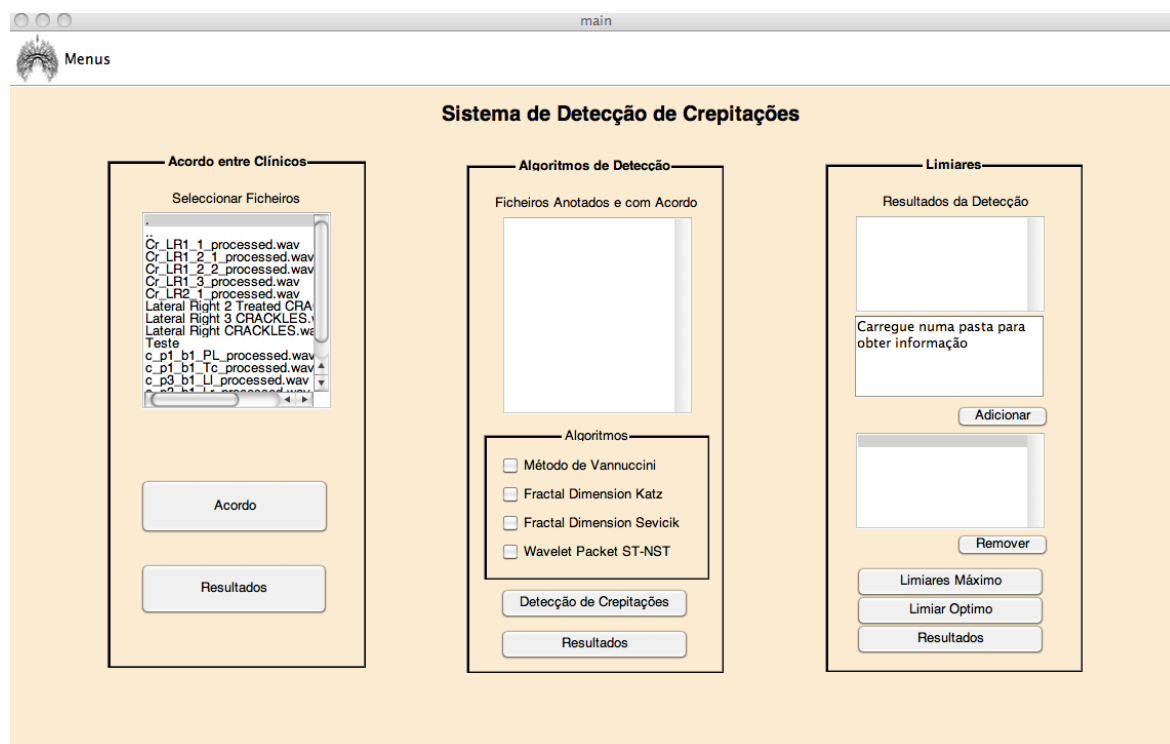


Figura A.1 – Janela ‘Sistema de Detecção de Crepitações’

Se o botão ‘Menus’ da Figura A.1 for seleccionado, surgem as opções existentes na interface (Figura A.2) . Que também podem ser invocadas usando o “rato” ou o teclado como mostra a Figura A.2.



Figura A.2 – Botão ‘Menus’

O primeiro menu (‘Detecção e Limiares’), permite aceder à janela ‘Sistema de Detecção de Crepitações’, já apresentada na Figura A.1, que incorpora as seguintes opções:

- ‘Acordo entre clínicos’
- ‘Algoritmos de Detecção’
- ‘Limiares’.

O segundo menu ('Acordo e Limiares'), permite aceder à janela 'Acordo entre Algoritmos de Detecção de Crepitações' Figura A.3, que incorpora as seguintes opções:

- 'Acordo entre Algoritmos'
- 'Limiar Máximo por Acordo'
- 'Acordo'

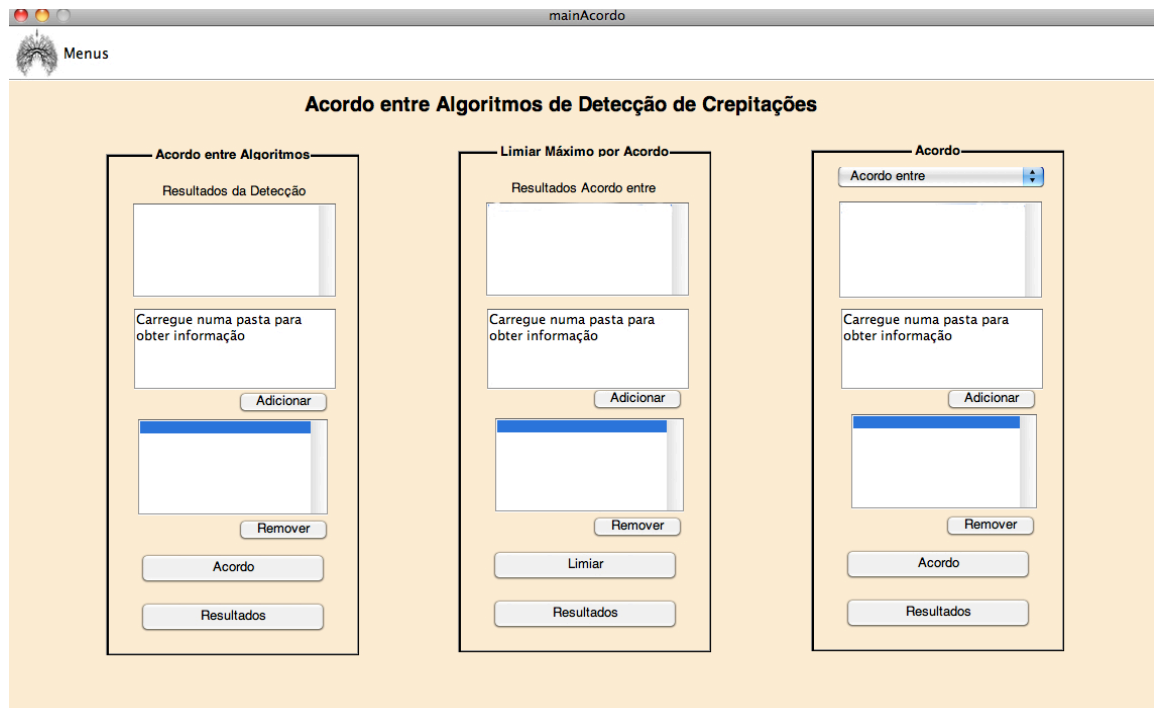


Figura A.3 – Janela 'Acordo entre Algoritmos de Detecção de Crepitações'

O terceiro menu ('Sair') serve, tal como nome indica, para sair da interface gráfica.

A.3 Procedimento

A interface pode ser utilizada seguindo o desenvolvimento do trabalho realizado nesta tese. Deste modo, a primeira janela utilizada foi 'Sistema de Detecção de Crepitações', apresentada na Figura A.1.

Em primeiro lugar foi necessário obter as anotações entre clínicos. Isso foi realizado através do menu 'Acordo entre clínicos' (Figura A.4) que permite obter anotações de referência para todos os ficheiros presentes.

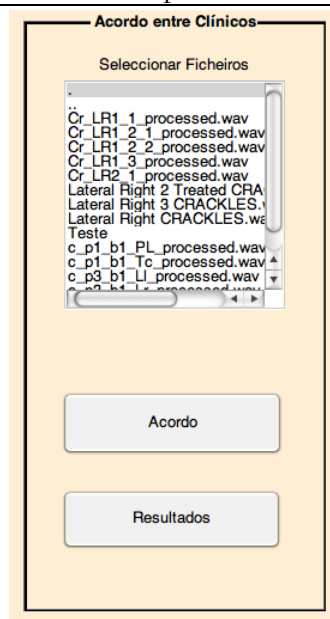


Figura A.4 – Menu ‘Acordo entre Clínicos’

Possuindo anotações de referência, o próximo passo consistiu em avaliar o desempenho dos algoritmos. Para esse efeito foi usado o menu ‘Algoritmos de Detecção’, presente na Figura A.5.

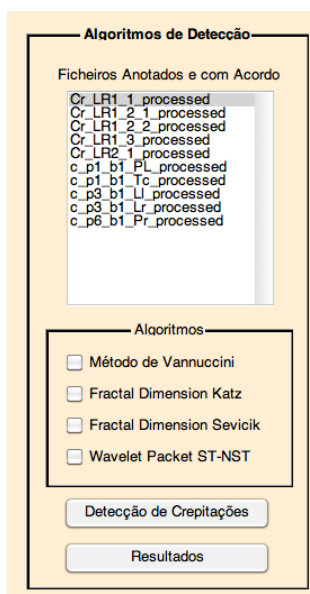


Figura A.5 – Menu ‘Algoritmos de Detecção’

Nele encontram-se os ficheiros em que se obteve anotações de referência. Este menu permite a avaliação de desempenho, em um ou mais ficheiros de uma só vez, e em um ou mais algoritmos por obtenção dos parâmetros SE, PPV e F. Além de permitir

selecionar a gama de limiares desejada para cada algoritmo (Figura A.6), também permite que se obtenha o desempenho de um algoritmo apenas para um único limiar (Figura A.7).

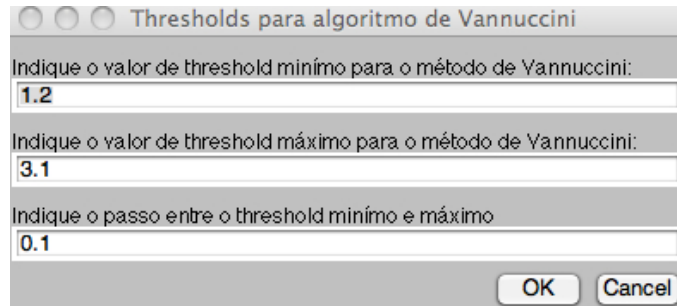


Figura A.6 – Executar vários limiares




Figura A.7 – Executar em apenas um limiar

De referir que não é possível processar duas vezes os mesmos limiares para o mesmo algoritmo.

Após a avaliação de desempenho, foi necessário obter os limiares máximos e o limiar óptimo de desempenho para os ficheiros nos algoritmos executados (Figura A.8).

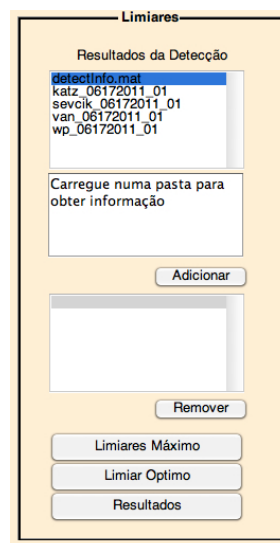


Figura A.8 – Menu 'Limiares'

É possível saber o nome do algoritmo, embora o nome da pasta já seja indicativo, os sons respiratórios analisados e os limiares utilizados em cada algoritmo, bastando carregar na pasta de que se deseja obter informação, sendo a informação disponibilizada na zona que diz ‘Carregue numa pasta para obter informação’ (Figura A.8).

Neste ponto, após a obtenção de todos os dados dos diferentes algoritmos, passou-se para a obtenção do acordo entre os algoritmos recorrendo às opções presentes na janela ‘Acordo entre Algoritmos de Detecção de Crepitações’) Figura A.3.

O acordo foi processado com o menu ‘Acordo entre Algoritmos’ (Figura A.9). Neste menu só é possível estabelecer acordo entre algoritmos quando os diferentes algoritmos detectarem crepitações nos mesmos ficheiros e possuírem a mesma quantidade de limiares.

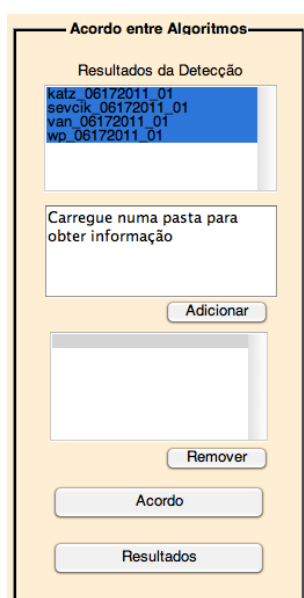


Figura A.9 – Menu ‘Acordo entre Algoritmos’

Após a obtenção do acordo procurou-se encontrar a combinação de limiares que oferecesse o máximo desempenho. Para isso usou-se o menu ‘Limiar Máximo por Acordo’ (vide Figura A.10).

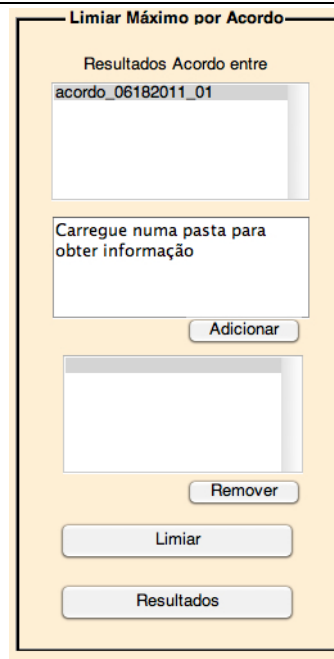


Figura A.10 – Menu ‘Limiar Máximo por Acordo’

Por fim, nesta janela, por uso do Menu ‘Acordo’ (Figura A.11) é possível obter o acordo entre os limiares de máximo e os limiares óptimos obtidos com o menu da Figura A.8.

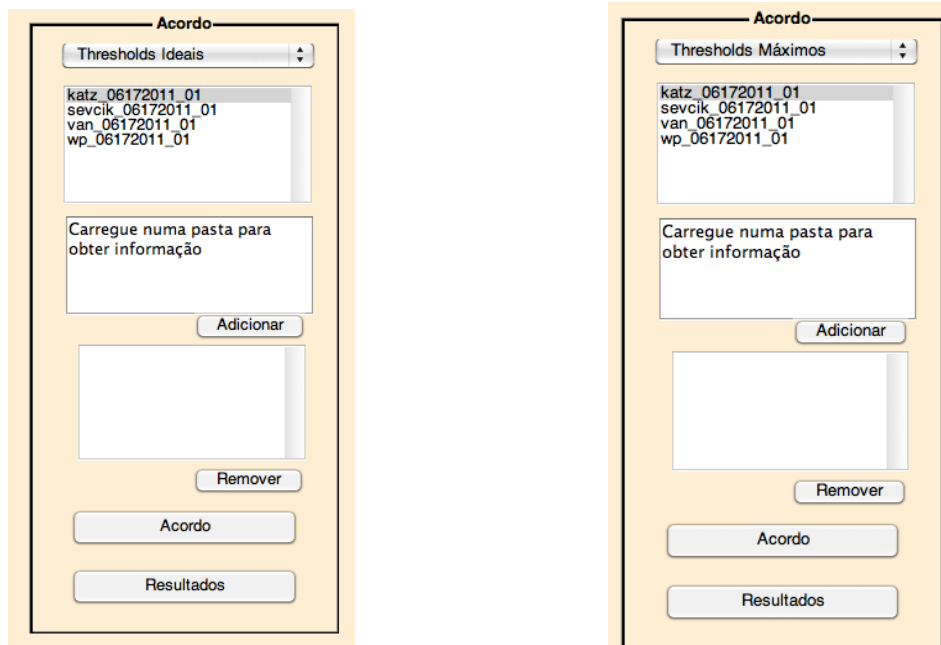


Figura A.11 – Menu de ‘Acordo’ com limiares óptimos e de máximos

Anexo B – Algoritmo de Acordo

Este anexo contém a informação relativa à implementação em *MatLab* do algoritmo de acordo. A lista de todos os *scripts* e ficheiros de dados utilizados é apresentada na tabela seguinte, em que se encontra também uma breve descrição de cada um.

Anotacoes/ (para mais de um som respiratório)	acordoFinal.m	Script do algoritmo de acordo
	Cr_LR1_1_processed	Crepitações anotadas (início e fim) por 3 profissionais de saúde.
	Cr_LR1_2_1_processed	
	Cr_LR1_2_2_processed	
	Cr_LR1_3_processed	
	Cr_LR2_1_processed	
	c_p1_b1_PL_processed	
	c_p1_b1_Tc_processed	
	c_p3_b1_Ll_processed	
	c_p3_b1_Lr_processed	
	c_p6_b1_Pr_processed	

Tabela B.1 – Scripts e Ficheiros de dados do algoritmo de acordo

Estes *scripts* e ficheiros de dados encontram-se na pasta ‘./Interface/Anotacoes/’ do CD de dados que integra esta dissertação (vide contracapa).

Anexo C – Algoritmo de Vannuccini et al.

Este anexo contém a informação relativa à implementação em *MatLab* do algoritmo de Vannuccini et al.. A lista de todos os *scripts* e ficheiros de dados utilizados é apresentada na tabela seguinte, em que se encontra também uma breve descrição de cada um.

Conjunto/ (para mais de um som respiratório)	run_dCrackles.m	<i>Script</i> principal que invoca todos os outros e onde são definidos parâmetros de entrada
	dcracklesFinalAlterado.m	Algoritmo de Vannuccini et al. (variante)
	dcracklesFinal.m	Algoritmo de Vannuccini et al. (versão original)
	infoCrackles.m	Anotação das crepitações (início e fim), para cada som respiratório
	infoEspSensFinal.m	Valores de SE e PPV
	infoSE_SP.m	Armazena os valores SE e PPV para cada som respiratório
	infoThreshVan.m	Parâmetros aplicados (limiares, frequência de amostragem ...)
	saveInfo.m	Conjunto completo da informação recolhida

Tabela C.1 – *Scripts* e ficheiros de dados do algoritmo de Vannuccini et al.

Estes *scripts* encontram-se na pasta ‘./Interface/Algoritmos/Vannuccini/’ do CD de dados que integra esta dissertação (vide contracapa).

Anexo D – Algoritmo de Hadjileontiadis e Rekanos

Este anexo contém a informação relativa à implementação em *MatLab* do algoritmo de Hadjileontiadis e Rekanos. A lista de todos os *scripts* utilizados é apresentada na tabela seguinte, em que se encontra também uma breve descrição de cada um.

Conjunto/ (para mais de um som respiratório)	run_FD.m	<i>Script</i> principal que invoca todos os outros e onde são definidos parâmetros de entrada
	FDDCracklesFinal.m	Algoritmo de Hadjileontiadis e Rekanos
	FDPIidentification.m	Algoritmo de detecção dos picos
	infoCrackles.m	Anotação das crepitações (início e fim), para cada som respiratório
	infoEspSensFinal.m	Valores de SE e PPV
	infoSE_SP.m	Valores SE e PPV para cada som respiratório
	infoThreshFD.m	Parâmetros aplicados (limiares, frequência de amostragem ...)
	threshFDD.m	Identificação dos picos
	saveInfo.m	Conjunto completo da informação recolhida

Tabela D.1 – *Scripts* do algoritmo Hadjileontiadis e Rekanos

Estes *scripts* encontram-se na pasta ‘./Interface/Algoritmos/Fractal Dimension/’ do CD de dados que integra esta dissertação (vide contracapa).

Anexo E – Algoritmo FD de Sevcik

Este anexo contém a informação relativa à implementação em *MatLab* do algoritmo FD de Sevcik. A lista de todos os *scripts* utilizados é apresentada na tabela seguinte, em que se encontra também uma breve descrição de cada um.

<p>Conjunto/ (para mais de um som respiratório)</p>	run_WP.m	<i>Script</i> principal que invoca todos os outros e onde são definidos parâmetros de entrada
	WP.m	Transformada <i>wavelet packet</i> (WP). (não activa)
	ST_NST.m	Separação do sinal (não activa)
	DS.m	Eliminação de ruído (não activa)
	WP_FD.m	<i>Fractal Dimension</i> pelo método de Sevcik
	ModWP_CPD.m	Deteção de crepitações
	infoCrackles.m	Anotação das crepitações (início e fim), para cada som respiratório
	infoThresh.m	Parâmetros aplicados (limiares, frequência de amostragem...)
	infoEspSensFinal.m	valores SE e PPV
	infoSE_SP.m	Valores SE e PPV para cada som respiratório
	saveInfo.m	Conjunto completo da informação recolhida

Tabela E.1 – *Scripts* de FD de Sevcik

Estes *scripts* encontram-se na pasta ‘./Interface/Algoritmos/WPST-NST/’ do CD de dados que integra esta dissertação (vide contracapa).

Anexo F – Algoritmo de Bahoura e Lu

Este anexo contém a informação relativa à implementação em *MatLab* do algoritmo de Bahoura e Lu. A lista de todos os *scripts* utilizados é apresentada na tabela seguinte, em que se encontra também uma breve descrição de cada um.

Conjunto/ (para mais de um som respiratório)	run_WP.m	<i>Script</i> principal que invoca todos os outros e onde são definidos parâmetros de entrada
	WP.m	Transformada <i>wavelet packet</i> (WP). (não activa)
	ST_NST.m	Separação do sinal (activa)
	DS.m	Eliminação de ruído (activa)
	WP_FD.m	<i>Fractal Dimension</i> pelo método de Sevcik
	ModWP_CPD.m	Deteção de crepitações
	infoCrackles.m	Anotação das crepitações (início e fim), para cada som respiratório
	infoThresh.m	Parâmetros aplicados (limiares, frequência de amostragem...)
	infoEspSensFinal.m	valores SE e PPV
	infoSE_SP.m	Valores SE e PPV para cada som respiratório
	saveInfo.m	Conjunto completo da informação recolhida

Tabela F.1 – *Scripts* e ficheiros de dados do algoritmo de Bahoura e Lu.

Estes scripts encontram-se na pasta ‘./Interface/Algoritmos/WPST-NST/’ do CD de dados que integra esta dissertação (vide contracapa).

Anexo G – Algoritmo SG-FD

Este anexo contém a informação relativa à implementação em *MatLab* do algoritmo SG-FD. A lista de todos os *scripts* utilizados é apresentada na tabela seguinte, em que se encontra também uma breve descrição de cada um.

Conjunto/ (para mais de um som respiratório)	run_SGFD	<i>Script</i> principal que invoca todos os outros e onde são definidos parâmetros de entrada
	SG.m	Transformada <i>wavelet packet</i> (WP). (não activa)
	WP_FD.m	<i>Fractal Dimension</i> pelo método de Sevcik
	ModWP_CPD.m	Detecção de crepitações
	infoCrackles.m	Anotação das crepitações (início e fim), para cada som respiratório
	infoThresh.m	Parâmetros aplicados (limiares, frequência de amostragem...)
	infoEspSensFinal.m	valores SE e PPV
	infoSE_SP.m	Valores SE e PPV para cada som respiratório
	saveInfo.m	Conjunto completo da informação recolhida

Tabela G.1 – *Scripts* do algoritmo SG-FD

Estes *scripts* encontram-se na pasta ‘./HibridoSG-FD/’ do CD de dados que integra esta dissertação (vide contracapa).

Anexo H – Acordo entre Algoritmos

Este anexo contém a informação relativa à implementação em *MatLab* do acordo entre Algoritmos. A lista de todos os *scripts* utilizados é apresentada na tabela seguinte, em que se encontra também, uma breve descrição de cada um.

AcordoThresh/ (para mais de um som respiratório)	acordoAlgFinal3.m	<i>Script</i> principal que invoca todos os outros e onde são definidos parâmetros de entrada. (para acordo entre 3 algoritmos)
	acordoAlgFinal4.m	<i>Script</i> principal que invoca todos os outros e onde são definidos parâmetros de entrada. (para acordo entre 3 algoritmos)
	HibAcordo.m	Algoritmo de Acordo
	infoCracklesHib.m	Anotação de crepitações (início e fim)
	infoSE_SP3.m.m	Valores SE e PPV (acordo entre 3 algoritmos)
	infoSE_SP4.m	Valores SE e PPV (acordo entre 4 algoritmos)
	infoThreshFD.m	Parâmetros aplicados(limiare, frequência de amostragem...) no algoritmo de Hadjileontiadis e Rekanos
	infoThreshSev.m	Parâmetros aplicados(limiare, frequência de amostragem...) no algoritmo FD de Sevcik
	infoThreshVan.m	Parâmetros aplicados(limiare, frequência de amostragem...) no algoritmo de Vannuccini et al.
	infoThreshWP.m	Parâmetros aplicados(limiare, frequência de amostragem...) no algoritmo de Bahoura e Lu
	saveInfo.m	Conjunto completo da informação recolhida

Tabela H.1 – *Scripts* do acordo entre algoritmos

Estes *scripts* encontram-se na pasta ‘./Interface/AcordoThresh/’ do CD de dados que integra esta dissertação (vide contracapa).

Referências

- [1] L. Vannuccini, M. Rossi, and G. Pasquali, "A new method to detect crackles in respiratory sounds.", *Technology and health care : official journal of the European Society for Engineering and Medicine*, vol. 6, pp. 75-79, Jul 1998.
- [2] L. J. Hadjileontiadis and T. Rekanos, "Detection of Explosive Lung and Bowel Sounds by Means of Fractal Dimension", *IEEE Transactions on Biomedical Engineering* vol. 47, pp. 1-4, Jul 31 2003.
- [3] C. Sevcik, "A procedure to Estimate the Fractal Dimension of Waveforms*", pp. 1-19, Apr 30 2010.
- [4] X. Lu and M. Bahoura, "An integrated automated system for crackles extraction and classification", *Biomedical Signal Processing and Control*, pp. 1-11, Jul 26 2008.
- [5] P. Piirila and A. R. Sovijarvi, "Crackles: recording, analysis and clinical significance", *The European respiratory journal : official journal of the European Society for Clinical Respiratory Physiology*, vol. 8, pp. 2139-48, Dec 1995.
- [6] A. A. Suki B, Hantos Z, Stanley HE., "Generation and propagation of crackle sound and it's relation to lung structure", presented at the Bioengineering Conference, 2001.
- [7] A. R. A. Sovijärvi, Dalmaso F, Sacco C, Rossi M and Earis J E "Characteristics of breath sounds and adventitious respiratory sounds", *European Respiratory Review*, vol. 10, pp. 591-596, 2000.
- [8] A. M. Hernandez, M. A. Maanas, and R. Costa-Castello, "Learning Respiratory System Function in BME Studies by Means of a Virtual Laboratory: RespiLab", *Education, IEEE Transactions on*, vol. 51, pp. 24-34, 2008.
- [9] J. F. Alonso, M. A. Mananas, D. Hoyer, Z. L. Topor, and E. N. Bruce, "Evaluation of respiratory muscles activity by means of cross mutual information function at different levels of ventilatory effort", *IEEE Trans Biomed Eng*, vol. 54, pp. 1573-82, Sep 2007.
- [10] M. G. Levitzky, *Pulmonary physiology*. New York; Toronto: McGraw-Hill, Medical Pub. Division, 2003.

- [11] J. B. West, *Respiratory Physiology : The Essentials*. Philadelphia, Pa.: Wolters Kluwer, 2008.
- [12] U.S. Department of Health & Human Services, National Institutes of Health, National Heart Lung and Blood Institute, [Online]. Available: http://www.nhlbi.nih.gov/health/dci/Diseases/hlw/hlw_what.html
- [13] R. T. H. Laennec. (1819). *De l'auscultation mediate; ou, Traite du diagnostic des maladies des poumons et du coeur, fonde principalement sur ce nouveau moyen d'exploration*. Available: <http://doi.library.cmu.edu/10.1184/OCLC/04481939>
- [14] Z. M. K. Moussavi, "Respiratory sound analysis [Introduction for the Special Issue]", *Engineering in Medicine and Biology Magazine, IEEE*, vol. 26, pp. 15-15, 2007.
- [15] R. Loudon and R. L. Murphy, Jr., "Lung sounds", *The American review of respiratory disease*, vol. 130, pp. 663-73, Oct 1984.
- [16] A. Marques, A. Bruton, and A. Barney, "The reliability of lung crackle characteristics in cystic fibrosis and bronchiectasis patients in a clinical setting", *Physiological measurement*, vol. 30, pp. 903-12, Sep 2009.
- [17] S. Reichert, R. Gass, C. Brandt, and E. Andres, "Analysis of respiratory sounds: state of the art", *Clinical medicine. Circulatory, respiratory and pulmonary medicine*, vol. 2, pp. 45-58, 2008.
- [18] A. Sovijarvi and J. Vanderschoot, *Computerized Respiratory Sound Analysis (CORSA): Recommended Standards for Terms and Techniques: ERS Task Force Report*, 2000.
- [19] H. Pasterkamp, S. S. Kraman, and G. R. Wodicka, "Respiratory sounds. Advances beyond the stethoscope", *American journal of respiratory and critical care medicine*, vol. 156, pp. 974-87, Sep 1997.
- [20] A. R. A. Sovijärvi, Dalmasso F, Vanderschoot J, Malmberg LP, Righini G, Stoneman SA, "Definition of terms for applications of respiratory sounds", *European Respiratory Review*, vol. 10, pp. 591-596, 2000.
- [21] N. Gavriely, Y. Palti, and G. Alroy, "Spectral characteristics of normal breath sounds", *Journal of applied physiology: respiratory, environmental and exercise physiology*, vol. 50, pp. 307-14, Feb 1981.
- [22] N. Gavriely, M. Nissan, A. H. Rubin, and D. W. Cugell, "Spectral characteristics of chest wall breath sounds in normal subjects", *Thorax*, vol. 50, pp. 1292-300, Dec 1995.
- [23] R. L. Wilkins, J. R. Dexter, R. L. Murphy, Jr., and E. A. DelBono, "Lung sound nomenclature survey", *Chest*, vol. 98, pp. 886-889, Oct 1990.
- [24] A. R. Nath and L. H. Capel, "Inspiratory crackles and mechanical events of breathing", *Thorax*, vol. 29, pp. 695-8, Nov 1974.
- [25] G. R. Epler, C. B. Carrington, and E. A. Gaensler, "Crackles (rales) in the interstitial pulmonary diseases", *Chest*, vol. 73, pp. 333-9, Mar 1978.
- [26] L. W. Wilkins, "Auscultation Skills: Breath and Heart Sounds," in *Auscultation Skills: Breath and Heart Sounds*, ed, 2009, pp. 156-157.
- [27] P. Forgacs, "Crackles and wheezes", *Lancet*, vol. 2, pp. 203-5, Jul 22 1967.
- [28] J. B. Grotberg and N. Gavriely, "Flutter in collapsible tubes: a theoretical model of wheezes", *Journal of applied physiology*, vol. 66, pp. 2262-73, May 1989.
- [29] T. Fawcett, "ROC graphs: Notes and practical considerations for researchers",

-
- Machine Learning*, 2004.
- [30] D. Sheng, "Feature Selection Based F-Score and ACO Algorithm in Support Vector Machine," in *Knowledge Acquisition and Modeling, 2009. KAM '09. Second International Symposium on*, 2009, pp. 19-23.
 - [31] J. Dinis, G. Campos, J. Rodrigues, and A. Marques, "Respiratory Sound Annotation Software (for submission to BIOSTEC 2012)", 2012.
 - [32] R. Murphy, E. Bono, and F. Davidson, "Validation of an Automatic Crackle (Rale) Counter", Nov 15 1989.
 - [33] R. L. H. Murphy, S. K. Holford, and W. C. Knowler, "Visual Lung-Sound Characterization by Time-Expanded Wave-Form Analysis", *New England Journal of Medicine*, vol. 296, pp. 968-971, 1977.
 - [34] S. Holford, "Discontinuous adventitious lung sounds: measurement, classification and modeling.," Doctoral Thesis, Cambridge; Massachusetts Institute of Technology, 1982.
 - [35] A. Cohen, "Signal processing methods for upper airway and pulmonary dysfunction diagnosis.," *Engineering in Medicine and Biology Magazine, IEEE*, vol. 9, pp. 72-75, 1990.
 - [36] ATS, "Update nomenclature for membership relation," ed: ATS News, 1977, pp. 3 5-6.
 - [37] J. Hoevers and R. G. Loudon, "Measuring crackles", *Chest*, vol. 98, pp. 1240-3, Nov 1990.
 - [38] P. Piirila, A. R. Sovijarvi, T. Kaisla, H. M. Rajala, and T. Katila, "Crackles in patients with fibrosing alveolitis, bronchiectasis, COPD, and heart failure", *Chest*, vol. 99, pp. 1076-83, May 1991.
 - [39] P. Piirila, "Changes in crackle characteristics during the clinical course of pneumonia", *Chest*, vol. 102, pp. 176-83, Jul 1992.
 - [40] M. Munakata, H. Ukita, I. Doi, Y. Ohtsuka, Y. Masaki, Y. Homma, and Y. Kawakami, "Spectral and waveform characteristics of fine and coarse crackles", *Thorax*, vol. 46, pp. 651-7, Sep 1991.
 - [41] G. Dorantes-Méndez, S. Charleston-Villalobos, R. Gonzalez-Camarena, G. Chi-Lem, J. G. Carrillo, and T. Aljama-Corrales, "Crackles detection using a time-variant autoregressive model.," *Conference proceedings : Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, vol. 2008, pp. 1894-1897, 2008.
 - [42] R. L. H. MURPHY, JR, E. A. D. BONO, and F. DAVIDSON, "Validation of an Automatic Crackle (Rale) Counter", pp. 1-4, Nov 15 1989.
 - [43] M. Ono, K. Arakawa, M. Mori, T. Sugimoto, and H. Harashima, "Separation of fine crackles from vesicular sounds by a nonlinear digital filter.," *IEEE transactions on bio-medical engineering*, vol. 36, pp. 286-291, Mar 1989.
 - [44] T. Kaisla, A. Sovijarvi, P. Piirila, H. M. Rajala, S. Haltsonen, and T. Rosqvist, "Validated method for automatic detection of lung sound crackles", *Medical & biological engineering & computing*, vol. 29, pp. 517-21, Sep 1991.
 - [45] J. Luo, K. Ying, and P. He, *Properties of Savitzky-Golay digital differentiators, Digit: Signal Prog*, 2005.
 - [46] L. Hadjileontiadis, "Nonlinear separation of crackles and squawks from vesicular
-

- sounds using third-order statistics", *Medicine and Biology Society*, vol. 5, pp. 2217-2219, 1996.
- [47] L. J. Hadjileontiadis and S. M. Panas, "Separation of discontinuous adventitious sounds from vesicular sounds using a wavelet-based filter", *IEEE transactions on bio-medical engineering*, vol. 44, pp. 1269-1281, 1997.
- [48] Y. P. Kahya, S. Yerer, and O. Cerid, "A wavelet-based instrument for detection of crackles in pulmonary sounds", presented at the Engineering in Medicine and Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE, 2001.
- [49] Y. P. Kahya, M. Yeginer, and B. Bilgic, "Classifying Respiratory Sounds with Different Feature Sets", *28th IEEE EMBS Annual International Conference, Aug 30-Sept. 3, 2006, New York City, New York, USA*, pp. 1-4, Jul 14 2006.
- [50] Y. P. Kahya and C. A. Yilmaz, "Modeling of respiratory crackles", presented at the Engineering in Medicine and Biology Society, 2000. Proceedings of the 22nd Annual International Conference of the IEEE, 2000.
- [51] Y. A. Tolia, L. J. Hadjileontiadis, and S. M. Panas, "Real-time separation of discontinuous adventitious sounds from vesicular sounds using a fuzzy rule-based filter.", *IEEE transactions on information technology in biomedicine : a publication of the IEEE Engineering in Medicine and Biology Society*, vol. 2, pp. 204-215, Sep 1998.
- [52] P. A. Mastorocostas and J. B. Theocharis, "A dynamic fuzzy neural filter for separation of discontinuous adventitious sounds from vesicular sounds.", *Computers in Biology and Medicine*, vol. 37, pp. 60-69, Feb 2007.
- [53] R. Esteller, G. Vachtsevanos, J. Echauz, and B. Litt, "A Comparison of Waveform Fractal Dimension Algorithms", pp. 1-7, Mar 22 2001.
- [54] L. J. Hadjileontiadis, "Wavelet-based enhancement of lung and bowel sounds using fractal dimension thresholding-part I: methodology", *Biomedical Engineering, IEEE Transactions on*, vol. 52, pp. 1143-1148, 2005.
- [55] M. J. Katz, "Fractals and the analysis of waveforms.", *Computers in Biology and Medicine*, vol. 18, pp. 145-156, 1988.
- [56] C. Sevcik, "On fractal dimension of waveforms ", *Letter to the Editor*, pp. 1-2, Sep 28 2005.
- [57] M. Bahoura and X. Lu, "2006 IEEE International Conference on Acoustics Speed and Signal Processing Proceedings", presented at the 2006 IEEE International Conference on Acoustics Speed and Signal Processing.
- [58] S. Charleston-Villalobos, R. González-Camarena, G. Chi-Lem, and T. Aljama-Corrales, "Crackle sounds analysis by empirical mode decomposition. Nonlinear and nonstationary signal analysis for distinction of crackles in lung sounds.", *Engineering in Medicine and Biology Magazine, IEEE*, vol. 26, pp. 40-47, 2007.
- [59] L. J. Hadjileontiadis, "A Novel Technique for Denoising Explosive Lung Sounds Empirical Mode Decomposition and Fractal Dimension Filter", *Engineering in Medicine and Biology Magazine, IEEE*, vol. 26, pp. 30-39, 2007.
- [60] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N. C. Yen, C. C. Tung, and H. H. Liu, "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis", *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 454, pp.

- 903-995, Apr 08 1998.
- [61] A. Marques, "The use of computer aided lung sound analysis to characterise adventitious lung sounds: a potencial outcome measure for respiratory therapy," PhD, University of Southampton, 2008.
 - [62] B. S. Raghavendra and D. N. Dutt, "A note on fractal dimensions of biomedical waveforms", *Computers in Biology and Medicine*, vol. 39, pp. 1006-1012, Sep 30 2009.
 - [63] P. Castiglioni, "What is wrong in Katz's method? Comments on: "A note on fractal dimensions of biomedical waveforms";" *Computers in Biology and Medicine*, vol. 40, pp. 950-952, Oct 2010.